


[Cilt/Volume:11] [Sayı/Issue:01] [Mayıs/May 2024] [Dergi No/Journal No.:119] [ISSN: 2147-1339] [e-ISSN: 2667-8519]

JEODEZİ VE JEOİNFORMASYON DERGİSİ

JOURNAL OF
GEODESY AND GEOINFORMATION



TMMOB

Harita ve Kadastro Mühendisleri Odası

UCTEA Chamber of Survey and Cadastre Engineers



TMMOB

Harita ve Kadastro Mühendisleri Odası

Yayıncı / Publisher

TMMOB Harita ve Kadastro Mühendisleri Odası
UCTEA Chamber of Surveying and Cadastre Engineers, Turkey

Yayın İdare Merkezi / Head Office

Mustafa Kemal Mahallesi 2129 Sk. No:1/7-8-9 06530 Çankaya, ANKARA, TURKEY
Tel: + 90 (312) 2325777 • Fax: + 90 (312) 2308574
jjd@hkmo.org.tr ; hkmojjd@gmail.com
dergipark.org.tr/hkmojjd

Tasarım ve Mizanpaj / Design & Layout

Önder Olgun Bökü

Baskı & Cilt / Printing & Binding

Boyut Matbaa
İvedik org.san.1354 Cadde. Fora İş Merkezi. 138/18 Yenimahalle / Ankara
E-Posta: info@boyutmatbaa.com Tel: +90 312 385 72 12

Basım Tarihi /Publication Date: Mayıs 2024 / May 2024

Baskı Adedi /Circulation: 2000

Hakemli bir dergidir. / A Peer - reviewed journal.

Yaygın ve süreli yayındır. / A widely distributed periodical.

Yılda iki defa yayımlanır (Mayıs - Kasım) / Published semiannually (May - November).

[Cilt/Volume:11] [Sayı/Issue:01] [Mayıs/May 2024] [Dergi No/Journal No.:119]

[ISSN: 2147-1339] [e-ISSN: 2667-8519]




UCTEA

Chamber of Survey and Cadastre Engineers

JEODEZİ VE JEOİFORMASYON DERGİSİ

JOURNAL OF
GEODESY AND GEOINFORMATION



TMMOB

Harita ve Kadastro Mühendisleri Odası

UCTEA Chamber of Survey and Cadastre Engineers

JEODEZİ VE JOURNAL OF GEODESY

EDİTÖR / EDITOR IN CHIEF

Prof. Dr. Bahattin ERDOĞAN
Yıldız Teknik Üniversitesi
İstanbul

EDİTÖR YARDIMCILARI / CO-EDITORS

Prof. Dr. Tarık TÜRK
Sivas Cumhuriyet Üniversitesi
Sivas

Prof. Dr. Nursu TUNALIOĞLU
Yıldız Teknik Üniversitesi
İstanbul

EDİTÖR KURULU / EDITORIAL BOARD

Prof. Dr. Arif Çağdaş AYDINOĞLU
Gebze Teknik Üniversitesi, Kocaeli

Prof. Dr. Atınc PIRTI
Yıldız Teknik Üniversitesi, İstanbul

Prof. Dr. Aydın ÜSTÜN
Kocaeli Üniversitesi, Kocaeli

Prof. Dr. Ayşe YAVUZ ÖZALP
Artvin Çoruh Üniversitesi, Artvin

Prof. Dr. Cemal Özer YİĞİT
Gebze Teknik Üniversitesi, Kocaeli

Prof. Dr. Cengizhan İPBÜKER
İstanbul Teknik Üniversitesi, İstanbul

Prof. Dr. Çetin CÖMERT
Karadeniz Teknik Üniversitesi, Trabzon

Prof. Dr. Çetin MEKİK
Hacettepe Üniversitesi, Ankara

Prof. Dr. Devrim AKÇA
Işık Üniversitesi, İstanbul

Prof. Dr. Ekrem TUŞAT
Konya Teknik Üniversitesi, Konya

Prof. Dr. Emine Tanır KAYIKÇI
Karadeniz Teknik Üniversitesi, Trabzon

Prof. Dr. Erol KÖKTÜRK
Okan Üniversitesi, İstanbul

Prof. Dr. Faik Ahmet SESLİ
Ondokuz Mayıs Üniversitesi, Samsun

Prof. Dr. Ferruh YILDIZ
Konya Teknik Üniversitesi, Konya

Prof. Dr. Halil AKINCI
Artvin Çoruh Üniversitesi, Artvin

Prof. Dr. Haluk ÖZENER
Boğaziçi Üniversitesi, İstanbul

Prof. Dr. Haluk KONAK
Kocaeli Üniversitesi, Kocaeli

Prof. Dr. Hülya DEMİR
Yıldız Teknik Üniversitesi, İstanbul

Prof. Dr. Hüseyin TOPAN
Zonguldak Bülent Ecevit Üniversitesi, Zonguldak

Prof. Dr. İbrahim Öztuğ BİLDİRİCİ
Konya Teknik Üniversitesi, Konya

Prof. Dr. İsmail Rakıp KARAS
Karabük Üniversitesi, Karabük

Prof. Dr. Mahmut Onur KARSLIOĞLU
Orta Doğu Teknik Üniversitesi, Ankara

Prof. Dr. Metin SOYCAN
Yıldız Teknik Üniversitesi, İstanbul

Prof. Dr. Mualla YALÇINKAYA
Karadeniz Teknik Üniversitesi, Trabzon

Prof. Dr. Murat UYSAL
Afyon Kocatepe Üniversitesi, Afyonkarahisar

Prof. Dr. Mustafa TÜRKER
Hacettepe Üniversitesi, Ankara

Prof. Dr. Naci YASTIKLI
Yıldız Teknik Üniversitesi, İstanbul

Prof. Dr. Nebiye MUSAOĞLU
İstanbul Teknik Üniversitesi, İstanbul

Prof. Dr. Necla ULUĞTEKİN
İstanbul Teknik Üniversitesi, İstanbul

Prof. Dr. Oğuz GÜNGÖR
Ankara Üniversitesi, Ankara

Prof. Dr. Özgün AKÇAY
Çanakkale Onsekiz Mart Üniversitesi, Çanakkale

Prof. Dr. Rahmi Nurhan ÇELİK
İstanbul Teknik Üniversitesi, İstanbul

Prof. Dr. Sebahattin BEKTAŞ
Ondokuz Mayıs Üniversitesi, Samsun

Prof. Dr. Sultan KOCAMAN GÖKÇEOĞLU
Hacettepe Üniversitesi, Ankara

Prof. Dr. Süleyman Savaş DURDURAN
Necmettin Erbakan Üniversitesi, Konya

Prof. Dr. Şenol Hakan KUTOĞLU
Zonguldak Bülent Ecevit Üniversitesi, Zonguldak

Prof. Dr. Taşkın KAVZOĞLU
Gebze Teknik Üniversitesi, Kocaeli

Prof. Dr. Uğur AVDAN
Eskişehir Teknik Üniversitesi, Eskişehir

Prof. Dr. Uğur DOĞAN
Yıldız Teknik Üniversitesi, İstanbul

Prof. Dr. Volkan ÇAĞDAŞ
Yıldız Teknik Üniversitesi, İstanbul

Doç. Dr. Ahmet Özgür DOĞRU
İstanbul Teknik Üniversitesi, İstanbul

Doç. Dr. Caner GÜNEY
İstanbul Teknik Üniversitesi, İstanbul

Doç. Dr. Melis UZAR,
Yıldız Teknik Üniversitesi, İstanbul

Doç. Dr. M. Tefvik ÖZLÜDEMİR
İstanbul Teknik Üniversitesi, İstanbul

Doç. Dr. Nusret DEMİR
Akdeniz Üniversitesi, Antalya

Doç. Dr. Saygın ABDİKAN
Hacettepe Üniversitesi, Ankara

Doç. Dr. Taylan ÖCALAN
Yıldız Teknik Üniversitesi, İstanbul

Dr. Öğr. Üyesi Ali Hasan DOĞAN,
Tokat Gaziosmanpaşa Üniversitesi, Tokat

Dr. Öğr. Üyesi Emin Özgür AVŞAR
Çanakkale Onsekiz Mart Üniversitesi, Çanakkale

Dr. Öğr. Üyesi Mehmet Güven KOÇAK
İzmir Katip Çelebi Üniversitesi, İzmir

Dr. Öğr. Üyesi Utkan Mustafa DURDAĞ
Artvin Çoruh Üniversitesi, Artvin

SAHİBİ (HKMO adına)

OWNER (on behalf of CSCE)

Ali İPEK

HKMO, Ankara

YAZI İŞLERİ MÜDÜRÜ

MANAGING EDITOR

Timur Bilinç BATUR

HKMO, Ankara

YAYIN KURULU / PUBLICATION BOARD

Bahattin ERDOĞAN, Yıldız Teknik Üniversitesi, İstanbul

Nursu TUNALIOĞLU, Yıldız Teknik Üniversitesi, İstanbul

Tarık TÜRK, Sivas Cumhuriyet Üniversitesi, Sivas

Taylan ÖCALAN, Yıldız Teknik Üniversitesi, İstanbul

Onur SEVENCAN, HKMO, Ankara

JEOİNFORMASYON DERGİSİ AND GEOINFORMATION

Dergi Hakkında

Jeodezi ve Jeoinformasyon Dergisi, TMMOB Harita ve Kadastro Mühendisleri Odası'na ait altı ayda bir yayımlanan (Mayıs ve Kasım ayları), hakemli, açık erişimli, süreli, özgün makalelerin yer aldığı bilimsel bir dergidir. Jeodezi ve Jeoinformasyon Dergisi, 2019 yılından itibaren ULAKBİM TR DİZİN'de yer almaktadır.

Amaç ve Kapsam

Jeodezi ve Jeoinformasyon Dergisi, jeodezi, jeoinformasyon bilimleri ve teknolojileri konularında geniş kapsamlı araştırma alanlarını içermektedir. Geleneksel çalışma alanlarının yanında, yer bilimleri, yere yönelik uzay bilimleri ve ilişkili disiplinler arası çalışmalara da dergide yer verilmektedir.

Dergide en az iki bilim insanı veya araştırmacı tarafından hakem değerlendirmesinden geçmiş, aşağıda listelenen alanlarda Türkçe veya İngilizce makaleler yayımlanmaktadır.

- Ölçme ve Algılama Sistemleri
- Matematiksel, Fiziksel, Uzay ve Mühendislik Jeodezisi
- Yer Bilimleri
- Uzaktan Algılama
- Fotogrametri
- Yere Yönelik Uzay Bilimleri
- Kartografya
- Coğrafi Bilgi Sistem ve Teknolojileri
- Arazi Yönetimi
- Yazılım Geliştirme

Makale Gönderme

Makale gönderme, değerlendirme ve düzenleme süreçleri <https://dergipark.org.tr/tr/pub/hkmojjd> sistemi üzerinden gerçekleştirilmektedir.

Telif Hakkı Bildirimi

Jeodezi ve Jeoinformasyon dergisi ücretsiz ve açık erişimli bir dergidir. Uygun şekilde kaynak göstermek koşulu ile makalenin herhangi bir bölümünün araştırma, çalışma, ders veya bilimsel ve teknik dokümanlarda kullanımı ücretsizdir. Ticari amaçla kopyalanması ve kullanımı TMMOB Harita ve Kadastro Mühendisleri Odası'ndan alınacak özel izne tabidir.

Yayın Etiği

Jeodezi ve Jeoinformasyon Dergisi bünyesindeki tüm yayınlar için yayın etiğini en yüksek standartlarda uygulamayı amaçlar ve "The Committee on Publication Ethics (COPE)" tarafından ortaya konulan kural ve ilkelere uymayı taahhüt eder.

About the Journal

Journal of Geodesy and Geoinformation is a peer-reviewed, semiannual (May and November), open access journal, which covers original scientific manuscripts, published by UCTEA Chamber of Surveying and Cadastre Engineers, Turkey. The Journal of Geodesy and Geoinformation has been indexed in ULAKBİM TR DİZİN since 2019.

Aim and Scopes

Journal of Geodesy and Geoinformation covers a broad range of research topics in geodetic and geoinformation sciences and technologies. Besides the traditional areas, it also includes study fields concerned with the earth sciences, earth-oriented space sciences and related interdisciplinary subjects.

The journal publishes peer-reviewed papers in the fields listed below in both English and Turkish, which are reviewed by at least two scientists and researchers.

- Surveying and Sensoric
- Mathematical, Physical, Space and Engineering Geodesy
- Earth Sciences
- Remote Sensing
- Photogrammetry
- Earth Oriented Space Sciences
- Cartography
- Geographical Information Systems and Technologies
- Land Management
- Software Development

Submission of Manuscript

Manuscript submission, review and editing processes are available on <https://dergipark.org.tr/en/pub/hkmojjd>

Copyright Information

Journal of Geodesy and Geoinformation is an open access and free of charge journal. There is no charge for use of any part of this publication in research, study, teaching or republications in scientific and technical documents, but the materials must be cited appropriately. Use and reproduction for commercial purposes requires special permission from Chamber of Surveying and Cadastre Engineers.

Publication Ethics

Journal of Geodesy and Geoinformation aims to apply high quality ethical standards for all publications and commits to obey the rules and principles of "The Committee on Publication Ethics (COPE)".

İÇİNDEKİLER

CONTENTS

ARAŞTIRMA MAKALELERİ / RESEARCH ARTICLES

- Yüksek voltajlı iletim hattı kamulaştırmalarında irtifak bedelinin hesaplanması için yeni bir yöntem önerisi
A new method proposal for calculating the easement price in high-voltage transmission line expropriations.....1-18
Seda Nur MARABAOĞLU, Bayram UZUN
- ESRI Land Cover ve Dynamic World arazi örtüsü verilerinin karşılaştırılması: Kıbrıs Adası örneği
Comparison of ESRI Land Cover and Dynamic World: The case of Cyprus Island..... 19-29
Ömer Gökberk NARİN
- İç mekân harita yapımı için makine öğrenmesiyle nokta bulutlarının sınıflandırılması
Classification of indoor point clouds using machine learning for indoor mapping..... 30-40
Sena VARBİL, Alper ŞEN
- Examining the accuracy of DEM of difference and 3D point cloud comparison methods: Open pit mine case study
Fark SYM ve 3B nokta bulutu karşılaştırma yöntemlerinin doğruluklarının incelenmesi: Açık maden ocağı örneği 41-50
Nilüfer ÖZDAŞ, Mehmet Güven KOÇAK, Serkan KARAKIŞ
- Coğrafi referanslı sosyal medya verilerinden doğal dil işleme ve derin öğrenme kullanılarak duygu analizi:
Kahramanmaraş depremleri örneği
Sentiment analysis from georeferenced social media data using natural language processing and deep learning:
The case of Kahramanmaraş earthquakes 51-67
Dilan Gözdem DOLU, Alper ŞEN
- Trimble RTX servisi kullanılarak uydu kombinasyonlarının hız kestirimine etkisinin incelenmesi
Investigation of the effect of satellite combinations on velocity estimation by using Trimble RTX service..... 68-79
Deniz Öz DEMİR

Yüksek voltajlı iletim hattı kamulaştırmalarında irtifak bedelinin hesaplanması için yeni bir yöntem önerisi

Seda Nur Marabaoğlu^{1*}, Bayram Uzun²

¹Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Gümüşhane, Türkiye.

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Trabzon, Türkiye.

Öz: Taşınmazlar üzerinden geçen yüksek voltajlı iletim hatları (YVİH) için irtifak kamulaştırması yapılmaktadır. Bu uygulama, 2942 sayılı Kamulaştırma Kanunu'nun yetersiz olması sebebiyle Yargıtay kararlarıyla yürütülmektedir. Her bir uygulama için yeni bir karar çıkarılmaktadır. Bu kararlar içinden, karşılaşılan yeni bir durumun çözümüne yönelik uygun hüküm aramak iş gücü ve zaman kaybı oluşturmaktadır. Taşınmaz değerini olumsuz etkileyen YVİH faktörleri ve bu faktörlerin değeri etkileme dereceleri de açık ve kesin değildir. Bu belirsizlik, irtifak bedelinin eksik veya fazla hesaplanmasına sebep olmaktadır. Bu çalışmada; yerli ve yabancı gayrimenkul değerlendirme uzmanlarıyla yapılan görüşmeler, ulusal ve uluslararası anket çalışmaları (20 farklı ülkeden katılımcı), Yargıtay kararları ve bilirkişi raporlarının incelemesi ile hâkim ve avukatlarla yapılan değerlendirmeler sonucunda YVİH'nin taşınmaz değerini etkileyen faktörler belirlenmiştir. Bu faktörler Analitik Hiyerarşi Yöntemi kullanılarak ağırlıklandırılmıştır. Böylelikle, irtifak bedelini otomatik olarak hesaplayan bir YVİH etki-değer modeli geliştirilmiştir. Node.js, Electron, TypeScript, React, Ant Design ve Webpack kullanılarak bu otomasyon modelinin arayüz yazılımı yapılmıştır. Model, Türkiye'deki çeşitli illerden toplanan 60 bilirkişi raporuyla test edilmiştir. Bu raporların 10 tanesi çalışmada örnek olarak gösterilmiştir. Otomasyon modeline göre, bilirkişi raporlarındaki yanılma oranı en az %17.21 ve en fazla %84.56 olarak bulunmuştur. Bu model, irtifak bedeli hesaplanmasında bir standart sağlayarak bu bedelin eksik veya fazla tespit edilmesi sorununu önemli ölçüde ortadan kaldıracaktır. İrtifak bedelinin tespitinde, kullanıcıların adım adım takip edebileceği tanımlı bir iş akış şeması mevcut olmadığı için hukuki süreçte karışıklık ve zaman kaybı meydana gelmektedir. Bu eksikliği gidermek için, hâkim ve avukatlarla değerlendirmeler yapılarak irtifak kamulaştırma uygulamalarındaki hukuki prosedürü hızlandıracak bir iş akış şeması oluşturulmuş ve çalışmada sunulmuştur.

Anahtar Sözcükler: İrtifak kamulaştırması, İrtifak bedeli, Değer düşüklüğü oranı, Yüksek voltajlı iletim hatları, Analitik hiyerarşi yöntemi

A new method proposal for calculating the easement price in high-voltage transmission line expropriations

Abstract: Easement expropriation is carried out for high voltage transmission lines (HVTL) passing over real estates. This practice is guided by the Supreme Court decisions due to the inadequacy of the Expropriation Law No. 2942. A new decision is made for each application. Among these decisions, searching for an appropriate provision to address a newly encountered situation results in both labor and time loss. HVTL factors that negatively affect the value of real estate and the degree to which these factors affect the value are not clear and certain. This uncertainty causes easement price to be underestimated or overestimated. In the study, the factors affecting the real estate value of HVTL were determined as a result of interviews with local and foreign real estate appraisers, national and international surveys (with participants from 20 countries), review of Supreme Court decisions and expert reports, and evaluations with judges and lawyers. These factors were weighted using the Analytic Hierarchy Process. Thus, a HVTL impact-value model was developed that automatically calculates the easement price. The interface software for this automation model was created using Node.js, Electron, TypeScript, React, Ant Design and Webpack. The model was tested with 60 expert reports collected from various provinces in Turkey. 10 of these reports are shown as examples in the study. According to the automation model, the error rate in expert reports was found to be at least 17.21% and at most 84.56%. This model will provide a standard in calculating the easement price and will significantly eliminate the problem of under- or over-determination of this price. Since there is no defined workflow chart that users can follow step by step in determining the easement price, confusion and loss of time occur in the legal process. In order to eliminate this deficiency, evaluations were made with judges and lawyers and a workflow chart that would speed up the legal procedure in easement expropriation applications was created and presented in the study.

Keywords: Easement expropriation, Easement price, Impairment rate, High voltage transmission lines, Analytical hierarchy process

* Sorumlu Yazar/Corresponding Author: Tel: +90 456 233 1000

Geliş Tarihi/Received: 13.07.2023

Kabul Tarihi/Accepted: 12.12.2023



1. Giriş

Elektrik üretim merkezlerinden yerleşim merkezlerine enerji iletiminin sağlanabilmesi için yüksek voltajlı iletim hatlarına (YVİH) ihtiyaç duyulmaktadır. Bu hatlar, üzerinden geçtiği her parselde birtakım kısıtlamalara sebep olduğundan, taşınmaz üzerinde irtifak hakkı kurulmakta ve irtifak kamulaştırması yapılmaktadır. İrtifak kamulaştırması, 4650 sayılı kanunla değişik 2942 sayılı Kamulaştırma Kanunu'na (4. ve 11. madde) göre yapılmaktadır. Ancak, uygulamada karşılaşılan sorunlara çözüm bulmakta bu kanun yetersiz kalmaktadır. Bu alanda bir yönetmelik de mevcut değildir. Dolayısıyla, bu süreç Yargıtay kararlarıyla yönetilmektedir (Marabaoğlu & Uzun, 2019). Karşılaşılan yeni bir irtifak sorununu çözmek için eski ve yeni yargı kararlarını incelemek, devletin iş yükünü artırmakta ve zaman kaybına sebep olmaktadır. Ayrıca, bu konuda standart bir hesaplama yönteminin olmamasından dolayı irtifak bedelleri genellikle eksik veya fazla hesaplanmaktadır. Bunun sonucunda, taşınmaz sahipleri mağdur olmakta veya devlet maddi kayıp yaşamaktadır. Bu durum, YVİH projelerinin uygulanmasında gecikmelere, dava sayılarının artmasına ve kamuoyu tepkisine sebep olmaktadır (Döner & Kaya, 2021). Benzer dosyalardaki irtifak bedelleri arasındaki fahiş farklılıklar da yargıya olan güveni azaltmaktadır.

1950'li yıllardan itibaren, YVİH'nin taşınmaz değeri üzerindeki etkisini değerlendirmek için birçok çalışma yapılmıştır. Yapılan ilk çalışmalar, taşınmaz sahipleri, değerlendirme uzmanları, bilirkişiler, emlakçılar ve kiracıların YVİH ile ilgili algı ve düşüncelerini incelemektedir. 1970 yılından önce yürütülen araştırmaların çoğunda, YVİH'lere yakınlık ile taşınmazlardaki değer kaybı arasında bir ilişki bulunmamış, hatta YVİH'ye yakın taşınmazların değerinin daha yüksek olduğu tespit edilmiştir. Buna örnek olarak, hatlara yakın konumda ikamet edenlerin konutlarını indirimli satmadığı ve kredi verenlerin bu taşınmazlar için kredi tutarlarında bir değişiklik yapmadığı gözlemlenmiştir (Carll, 1956). 1970 yılından sonra yürütülen çoğu araştırmada ise, YVİH kurulu bölgede ikamet edenlerin, hatların taşınmazda görsel rahatsızlığa ve değer kaybına sebep olacağına inandıkları tespit edilmiştir (Callanan, 2010; Gallimore & Jayne, 1999; Soini vd., 2011; Solum, 1985). Bazı çalışmalarda, potansiyel sağlık riskleri, hatlardan gelen cızırtı, uğultu (ses rahatsızlığı) ve güvenlik kaygısı da değeri etkileyen faktörler arasında sayılmıştır (Delaney & Timmons, 1992; Jain vd., 2019; Priestley & Evans, 1996; Seiler, 2014; Wadley vd., 2017; Wyman & Mothorpe, 2018). Kung ve Seagle (1992)'in yaptığı çalışmada, taşınmaz sahiplerinin bir kısmı, YVİH'ye yakın taşınmaz satın alırken düşük bir fiyat ödeyebileceklerini veya başka bir bölgeden taşınmaz satın alacaklarını ifade etmiştir. Elliott ve Wadley (2012)'in yaptığı çalışmada da bölge halkı, mülkiyet haklarına müdahale, çevresel zarar ve estetik konularında hatlardan kaygılı olduklarını belirtmiştir.

YVİH'nin etkisini azaltmak için; etki faktörlerinin tespit edilmesi, bilgiye erişimin iyileştirilmesi ve karar alma sürecinde yerel katılımın artırılması gerekmektedir. Söz konusu çalışmalar, aidiyet duygusu yüksek olan kişilerin yaşadıkları bölgede YVİH kurulumuna daha fazla itiraz ettiğini göstermiştir (Devine-Wright, 2013).

Değerleme uzmanlarına göre, YVİH'nin kaldırıldıktan sonra taşınmaz değeri üzerindeki etkisi (stigma: damgalama) devam etmektedir (Akinjare vd., 2013). Avustralya'da YVİH'nin kaldırılmasından önce ve sonra taşınmaz değerinde oluşan etkiyi belirlemek için vaka çalışması yöntemiyle nicel bir analiz yapılmıştır. Analizde, YVİH kaldırıldıktan sonra etkinin ne kadar devam edeceği ve taşınmaz değerinin piyasa değerine eşdeğer seviyeye dönüp dönmeyeceği incelenmiştir. YVİH'nin kaldırılmasından 3 yıl önce ve 10 yıl sonraki 2316 adet taşınmaz verisi hedonik fiyat modeli kullanılarak analiz edilmiştir. Pilonların 50 m dâhilindeki konutlarda %5 ila %27 değer kaybı olduğu tespit edilmiştir. YVİH'nin kaldırılmasından sonra, bir taşınmazın değerinin piyasa değerine ulaşması için 2 yıl geçmesi gerektiği hesaplanmıştır. YVİH kurulu iken sadece yakınlardaki konutların olumsuz etkilendiği, YVİH'nin kaldırılmasından sonra ise yerleşim bölgesindeki bütün taşınmazların değerinin arttığı görülmüştür. Dolayısıyla, YVİH kurulu iken yerleşim bölgesindeki bütün taşınmazların değerinin olumsuz etkilendiği gerçeğinin göz ardı edildiği tespit edilmiştir (Callanan, 2017).

YVİH'nin görsel etkisini ortadan kaldırmak için hatların yer altına gömülmesi veya kaldırılmasındaki ek maliyetleri ödeme hususunda taşınmaz sakinlerinin istekli olup olmadığını öğrenmeye yönelik koşullu değerlendirme (Contingent Valuation-CV) çalışmaları yapılmıştır. Yakınlık faktörünün taşınmaz değerine etkisi olduğunu düşünen katılımcıların, hatların kaldırılması için 4.781 \$ ödemeye istekli oldukları belirtilmiştir (Giaccaria vd., 2010; Navrud vd., 2008). Başka bir çalışmada, katılımcılar YVİH'den kaynaklanan görsel bozukluğun giderilmesi için aylık olarak yaklaşık 0.1 \$, arazi kullanımındaki kısıtlama için ise aylık olarak km² başına 0.12 \$ ödeyebileceklerini belirtmiştir (Ju & Yoo, 2014). Yine bir çalışmada, 3846 taşınmaz sakininin %50'si hatların yeraltına döşenmesi politikasını desteklemiştir (Tempesta vd., 2014).

Konuyla ilgili istatistiksel çalışmalar 1970 yılından sonra yapılmaya başlanmıştır. Bu çalışmalar, YVİH ve/veya pilonlara bitişik, yakın ve uzak taşınmazların satış fiyatlarının istatistiksel bir karşılaştırması ve analizine dayanmaktadır. Çalışmaların çoğunda, YVİH'ye yakın taşınmazların değerinin hattan uzaktakilere göre daha fazla düştüğü tespit edilmiştir (Bottemiller & Wolverton, 2013; Pitts & Jackson, 2007; Sims vd., 2009). Amerika Birleşik Devletleri'nde 200 adet taşınmazın satış verisi analiz edilmiştir. 138 kV hatlardan 15 m mesafedeki taşınmazlarda ortalama %8, 61 m mesafedeki taşınmazlarda ise ortalama %3 değer düşüklüğü bulunmuştur (Colwell, 1990). Bazı çalışmalarda, pilona 10-15 m mesafedeki taşınmazın değerinin ortalama %20 oranında olumsuz etkilendiği, bu etkinin 50 m'de %5'e düştüğü, 100 m'den sonra ise azaldığı veya tamamen kaybolduğu tespit edilmiştir (Bond & Hopkins, 2000; Callanan, 2013; Des Rosiers, 2002; Tatos vd., 2016; Thomas & Welke, 2017). Ayrıca, en yakın pilyondan 300-350 m uzaklıkta bulunan konutların değeri, pilyondan 50 m uzaklıktaki konutlara göre %7 daha yüksek çıkmıştır (Sims, 2005). Taşınmaz değeri üzerindeki en olumsuz etkinin "konuttan pilyonun 3/4'ünün görünmesi" faktörü olduğu görülmüştür. Bir pilyonun 50 m dâhilindeki bir konutun, hattın geçtiği parsel üzerinde bulunmamasına rağmen %19 değer düşüklüğüne uğradığı tespit edilmiştir (Sims & Dent, 2005). Çok değişkenli ANOVA yöntemiyle analiz yapılan iki çalışmada ise, YVİH'den uzaklığın artmasıyla kira değerlerinin de arttığı gözlemlenmiştir (Akinjare vd., 2012; Rotimi & Joseph, 2014).

Bazı çalışmalarda, küçük boyutlu taşınmazın büyük boyutlu taşınmaza göre YVİH'den daha fazla etkilendiği tespit edilmiştir. Çünkü küçük parselde yapılan küçük bir müdahale, taşınmazın haklarını (imar hakkı vb.) daha hızlı (büyük parselde göre) sınırlandırabilmektedir. Ayrıca, yerleşim bölgelerindeki taşınmazların tarımsal alanlardaki taşınmazlara göre YVİH'den daha fazla etkilendiği bulunmuştur (Chalmers, 2012; Kroll & Priestly, 1992).

Yapılan çalışmaların bazıları, bölgeye YVİH kurulduktan sonra taşınmazların değerinin arttığını göstermiştir. Bir çalışmada, 1800'den fazla taşınmazın satış verisi kullanılarak regresyon analizi yapılmış ve irtifak alanının peyzajına bisiklet yolları, yürüyüş yolları, vb. unsurlar eklendiğinde konutların değerinin %10 oranında arttığı gözlemlenmiştir (Ignelzi & Priestly, 1991). Regresyon analizi kullanılarak yapılan başka çalışmalarda ise, taşınmaza olan muhtemel ulaşım imkanının artması veya mahremiyet sebebiyle de taşınmazda %19 ila %35 oranında olumlu bir etki bulunmuştur (Jackson vd., 2012; Sims & Dent, 2013; Tatos vd., 2016).

YVİH'nin yaydığı elektromanyetik alanın sağlık üzerinde etkisi olup olmadığını araştırmak için de çalışmalar yapılmıştır. Bazı çalışmalarda, hatlara yakın ikamet eden kişilerde, lösemi ve diğer kanser türlerine yakalanma riskinin arttığı bulunmuştur (Sermage-Faure vd., 2013; Kheifets vd., 2010). Bazılarında ise, hatlara yakınlık ile hastalığa yakalanma riski arasında anlamlı bir ilişki olmadığı tespit edilmiştir (Bunch vd., 2015; Gervasi vd., 2019).

Bu makalede, irtifak bedelinin tespitindeki belirsizlikleri ve adil olmayan uygulamaları ortadan kaldırmak için; taşınmaz değerini etkileyen faktörlerin tespit edilerek ağırlıklandırılması, her faktörün değere etkisinin bulunması ve bu etkiyi değer düşüklüğü oranına yansıtarak irtifak bedeli tespit eden standart bir YVİH etki-değer otomasyon modelinin oluşturulması amaçlanmıştır. Faktörler; Türkiye'nin sosyo-ekonomik yapısı gözetilerek, akademik literatür araştırması yapılarak, yerli ve

yabancı gayrimenkul değerlendirme uzmanları ile anket çalışması yapılarak, mevcut Yargıtay kamulaştırma kararları ve bazı illere ait bilirkişi raporları incelenerek ve bu alanda aktif görevde olan hâkim ve avukatlarla değerlendirmeler yapılırak belirlenmiştir. Belirlenen faktörlerin etki ağırlıkları, ulusal ve uluslararası ölçekte yapılan anket çalışması verilerinin Analitik Hiyerarşi Yöntemi (AHY) kullanılarak değerlendirilmesiyle belirlenmiştir. Oluşturulan otomasyon programı ile irtifak bedelinin gerçeğe daha yakın olarak tespit edilmesi, böylece taşınmaz sahiplerinin mağduriyetlerinin önlenmesi ve kamu kaynaklarının daha verimli kullanılması hedeflenmiştir.

2. Kamulaştırma Yoluyla İrtifak Hakkı Tesisi Süreci

Arsa ve arazi nitelikli parseller üzerindeki pylon alanları ve trafo merkezleri için mülkiyet, iletim hatları için ise irtifak kamulaştırması yapılmaktadır. İrtifak kamulaştırması, 2942 sayılı Kamulaştırma Kanunu'na göre yapılmaktadır. Taşınmazın niteliğine göre Kamulaştırma Kanunu'nun 11. maddesinin 2. fıkrası hükmü gereğince taşınmazın tamamının bir bütün olarak değeri tespit edildikten sonra aynı maddenin son fıkrası uyarınca irtifak kurulması sebebiyle taşınmazda meydana gelecek değer düşüklüğünün oranı ve tutarı gerekçeleriyle belirtilmelidir. İrtifak kurulması sebebiyle taşınmazda meydana gelecek değer düşüklüğü; taşınmazın cinsi, niteliği, kullanım şekli, üzerinde bulunan bina, ağaç, vb. unsurların etkilenip etkilenmediği, irtifak hakkının niteliği (boru hattı, enerji nakil hattı, vb.), irtifakın alanı, konumu, mesafesi ve istikameti dikkate alınarak belirlenmektedir. YVİH geçen taşınmazın irtifak hakkı kurulmasından önceki bütün değerinin tespit edilmesi, bundan sonra hat sebebiyle taşınmazın tamamında meydana gelecek değer düşüklüğü oranının belirlenmesi ve bu oranla taşınmazın bütün değerinin çarpılması sonucu irtifak hakkı karşılığının hesaplanması gerekmektedir. Taşınmazın zemin ve (varsa) üzerinde ağaç ve yapı bedelleri toplamı esas alınarak (varsa) pylon yeri yüzölçümü düşüldükten sonra geri kalan alanda enerji nakil hattı geçirilmesi sebebiyle meydana gelen değer düşüklüğü oranı belirlenip taşınmazın toplam değeri ile bu oran çarpılmak suretiyle irtifak bedeli belirlenmelidir (Y5HD-2.7.2014 tarih E.2014/10160 ve K.2014/19550). Yargıtay kararına göre, üzerinde irtifak kurulmuş olan taşınmazda irtifak sebebiyle oluşacak değer düşüklüğünün (taşınmazın cins ve niteliğinin uygun kullanımını önemli ölçüde etkileyen özel bir durum yoksa) irtifaktan etkilenen alanın mülkiyet değerinin arazide %35'ini, arsada ise %50'sini geçmeyeceği kabul edilmektedir. Bu hükme göre hesaplama formülleri aşağıdaki gibidir.

$$IKB = DDO(\%) \times F \times M \quad (1)$$

$$Arsalar için DDO = (\dot{I}HA \times \%50)/F \quad (2)$$


$$Araziler için DDO = (\dot{I}HA \times \%35)/F \quad (3)$$

Burada F taşınmazın alanını, M taşınmazın zemin m^2 birim değerini, $\dot{I}HA$ irtifak hakkı alanını, IKB irtifak kamulaştırma bedelini, DDO ise değer düşüklüğü oranını ifade etmektedir.

İrtifak kamulaştırma uygulamalarında yargı bilirkişileri, taşınmazın niteliğini, irtifak değerini etkileyen faktörleri yeterince dikkate almadan, irtifak için en yüksek değer düşüklüğü oranı olan %35 veya %50 değerlerini kullanmaktadır. Bu durum, irtifak bedelinin olması gerektiğinden fazla hesaplanmasına ve YVİH kurulum maliyetlerinin artmasına sebep olmaktadır. Ayrıca, taşınmaz sahipleri haksız şekilde zenginleşebilmekte, emlak piyasasında ise çeşitli spekülasyonlar ortaya çıkabilmektedir (Yılmaz & Alkan, 2022).


YVİH, 30.11.2000 tarihinde 24246 sayılı Resmî Gazete'de yayınlanarak yürürlüğe giren Elektrik Kuvvetli Akım Tesisleri (EKAT) Yönetmeliğinde belirtilen emniyet mesafelerine (yatay ve düşey) göre kurulmaktadır. Buna göre, kurulan hattın

irtifak alanı belirlenmekte (Şekil 1) ve irtifak kamulaştırması yapılmaktadır.



Şekil 1: İrtifak hakkı alanının gösterimi

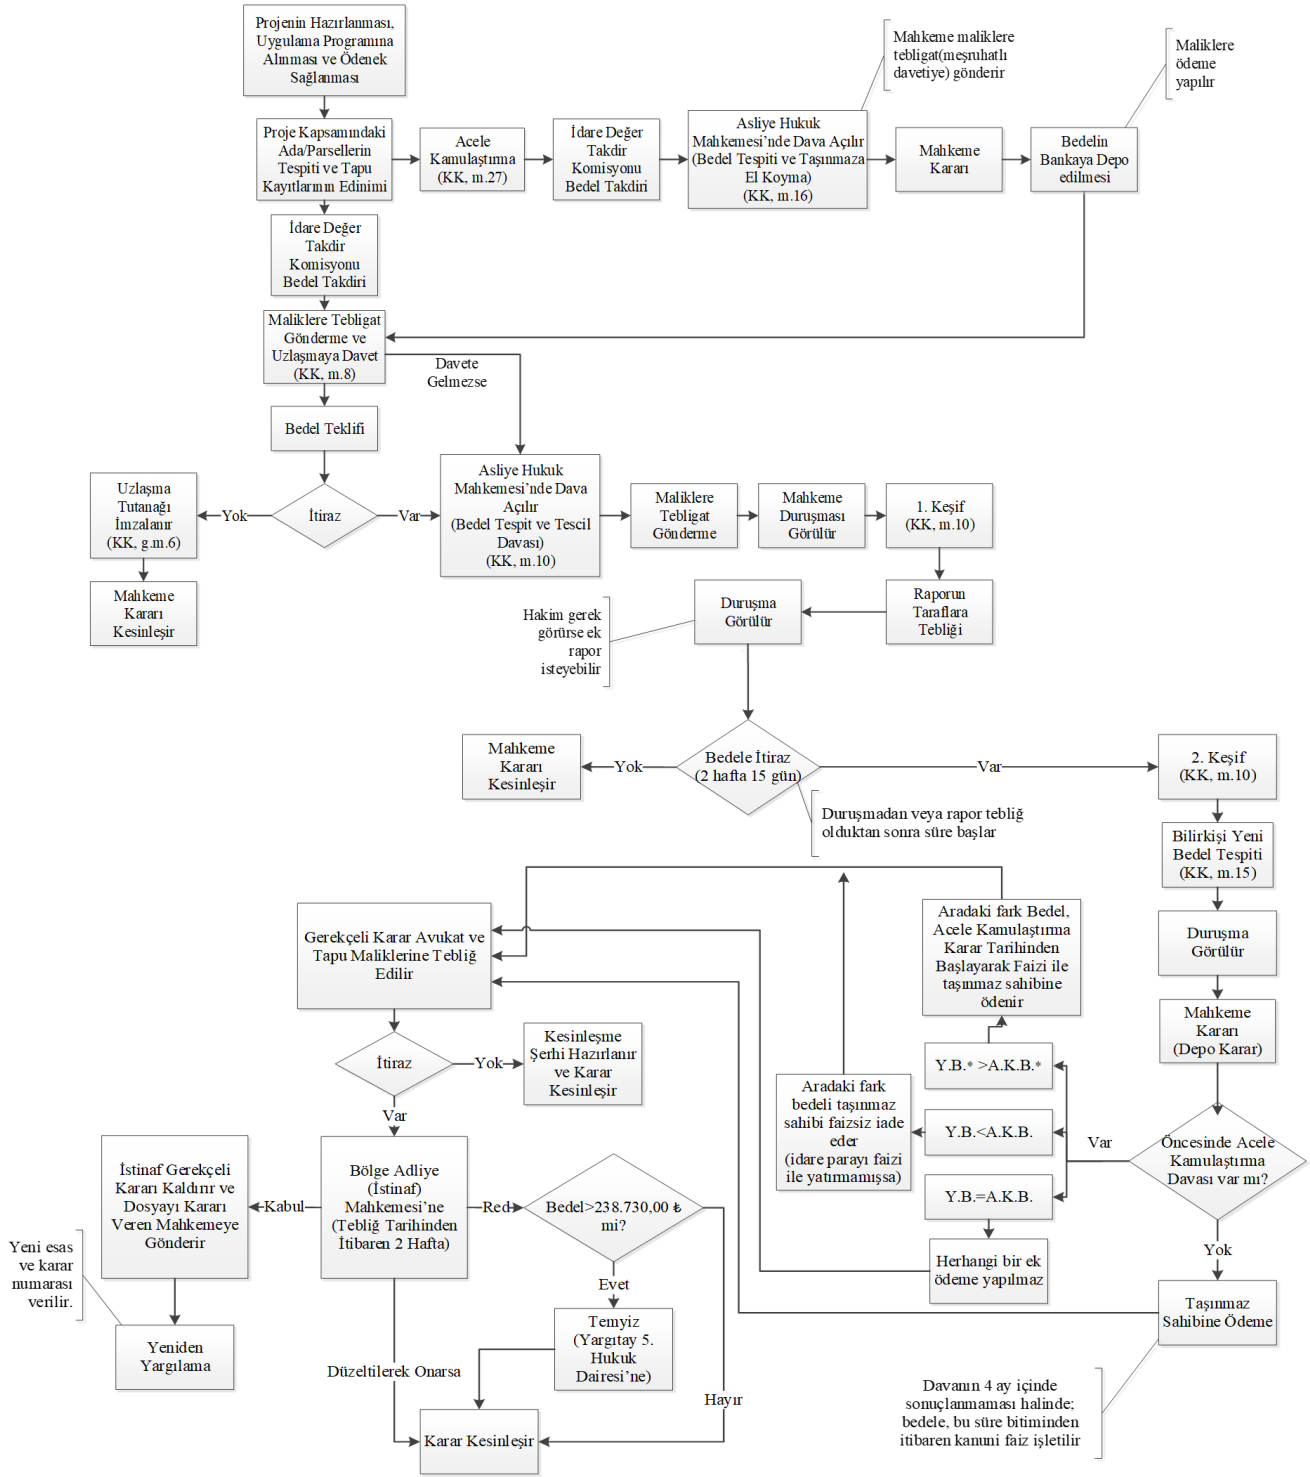
İrtifak kamulaştırmasında idare, ilgili taşınmazın mülkiyetini devralmak yerine, taşınmazın belirli bir kesiminde (yüksekliğinde, derinliğinde veya üzerinde) kendi lehine irtifak hakkı tesis etmektedir. Böylelikle; hem idare, mülkiyet için ödeyeceği kamulaştırma bedelinden daha az bir bedel ödemekte hem de taşınmaz üzerinde irtifak yoluyla kamulaştırma işlemi yapılmadan taşınmaz sahibi, taşınmazı üzerinde tasarrufta bulunma hakkını korumaya devam etmektedir. YVİH sebebiyle irtifak kamulaştırması büyük oranda Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) tarafından yapılmaktadır. YVİH, EKAT Yönetmeliği'nin 44. ve 46. maddelerinde belirtilen yatay (s) ve düşey (d) emniyet mesafelerine (Petrol ve doğalgaz boru hatlarına, konutlara, vb.) uyularak tesis edilmektedirler (Şekil 2). Örnek vermek gerekirse; yönetmeliğe göre 420 kV hattın en büyük salgı durumunda üzerinden geçtiği binalara en küçük yatay uzaklığı 5 m, en küçük düşey uzaklığı ise 8.7 m olmalıdır.



Şekil 2: YVİH'nin yatay ve düşey emniyet mesafeleri

İrtifak hakkı tesis edilirken izlenmesi gereken işlem adımlarını gösteren bir rehber mevcut değildir. Bu sebeple, kullanıcıların idari ve adli yargılama süreçlerini açık bir şekilde takip edebileceği bir iş akış şeması oluşturulmuştur. Hâkim ve avukatlarla görüşülerek oluşturulmuş olan bu şema Şekil 3'te verilmiştir. Şekildeki 238 730 TL meblağlı bedel, 2023 yılı için belirlenmiştir. Miktar ve değeri 238 730 TL'yi geçmeyen (238 730 TL dahil - 2023 yılı için) davalara dair istinaf mahkemesi

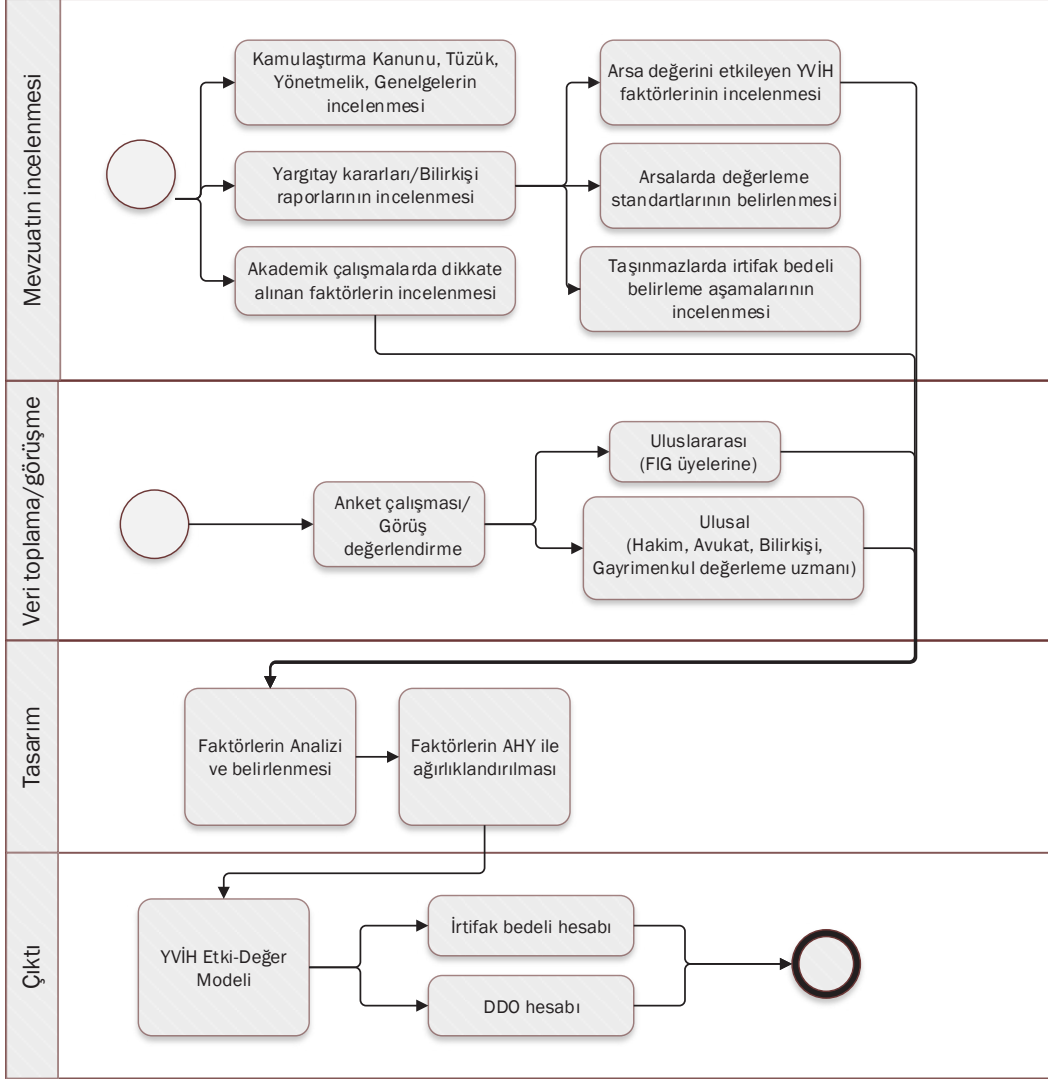
kararları kesin olup aleyhine temyiz başvurusu yapılamaz (HMK md.362/1-a).



Şekil 3: İrtifak kamulaştırması iş akış şeması

3. Yöntem ve Uygulama


Bu çalışmada takip edilen sürecin daha açık ve anlaşılır olması için oluşturulan iş akış şeması Şekil 4'te verilmiştir.



Şekil 4: Çalışmada izlenen yönteme ait iş akış şeması

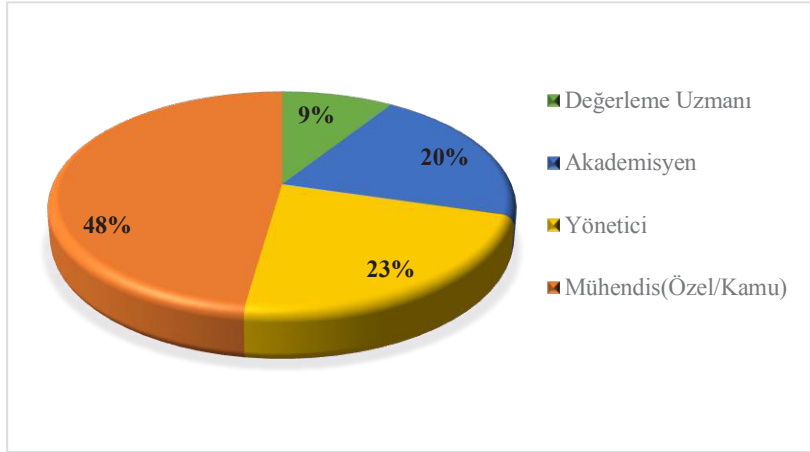
3.1 Faktörlerin Belirlenmesi

Kanun, tüzük, yönetmelik, genelge, Yargıtay kararları ve bilirkişi raporlarında irtifak kamulaştırma süreci ve irtifak bedeli belirlenirken dikkate alınan/alınması gereken faktörler incelenmiştir. Bilirkişiler, gayrimenkul değerlendirme uzmanları ve akademisyenlerle değerlendirmeler yapılmıştır. Bütün bunların sonucunda, YVİH faktörleri belirlenmiştir. Faktörlerin taşınmazı ne kadar etkilediğini tespit etmek için iki farklı anket çalışması yapılmıştır. Ulusal anket, Türkiye'deki hâkim, avukat, bilirkişi, gayrimenkul değerlendirme uzmanı ve bu alanda danışmanlık yapan akademisyenlere uygulanmıştır. Ankete 35 kişi katılmıştır. Şekil 5'te katılımcıların meslek dağılım grafiği verilmiştir.



Şekil 5: Ulusal anket katılımcıları meslek dağılım grafiği

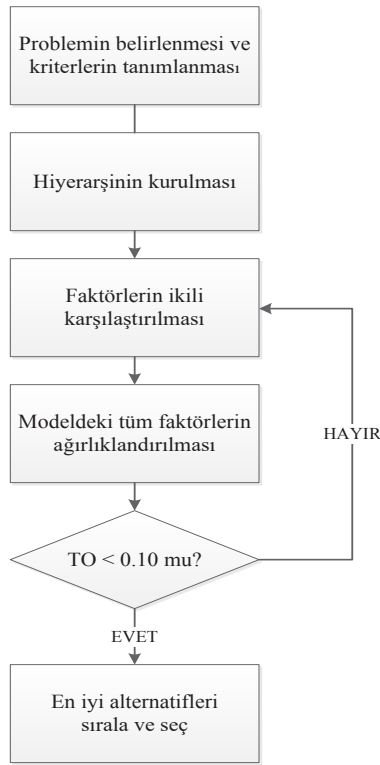
Uluslararası anket, Uluslararası Haritacılar Birliği (International Federation of Surveyors, FIG) kongresine katılan farklı sektörlerdeki harita mühendislerine uygulanmıştır. Bu ankete ise 20 farklı ülkeden 44 kişi katılmıştır. Şekil 6’da katılımcıların meslek dağılım grafiği verilmiştir. Anket yüz yüze gerçekleştirildiği için, bazı ülkelerdeki mevcut durum ve uygulamalarda karşılaşılan veya karşılaşılabilecek sorunlar hakkında katılımcılardan somut bilgi ve fikirler elde edilebilmiştir.



Şekil 6: Uluslararası anket katılımcıları meslek dağılım grafiği

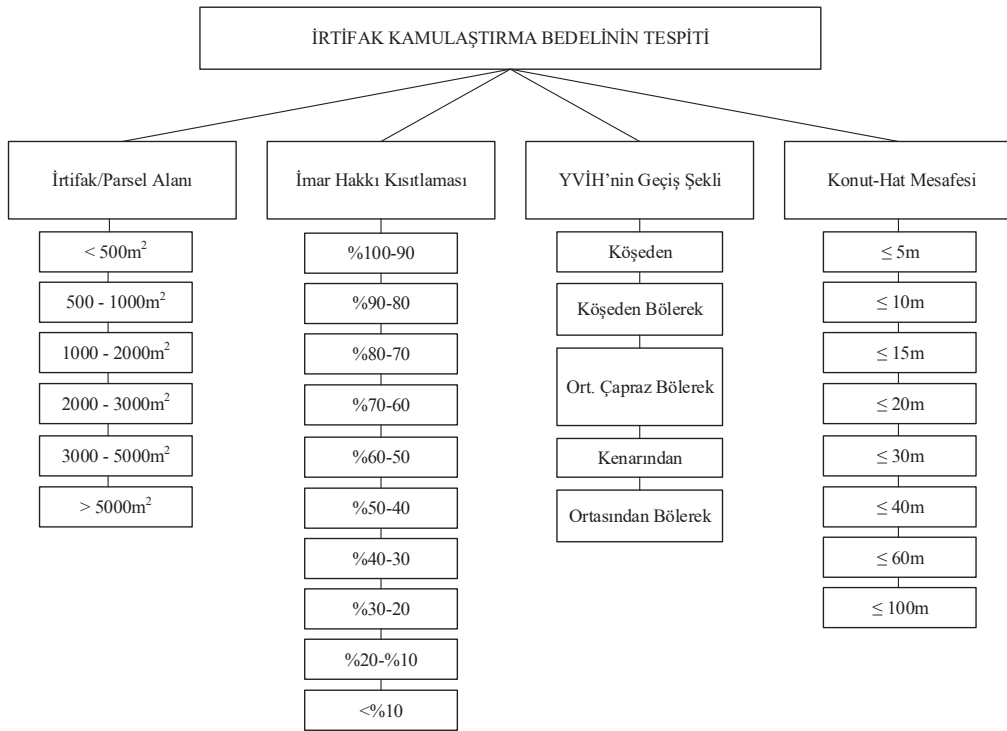
Anketlere katılan toplam kişi sayısı 79’dur. Her iki ankette de katılımcılardan, YVİH’nin taşınmaz değerine etkisinde dikkate alınan faktörleri (Şekil 8’de verilen) “AHY Saaty Ölçek Tablosu” kullanarak puanlandırmaları (1’den 9’a) istenmiştir.

Çalışmada, AHY kullanılmıştır. Bu yöntem, birden fazla kriter içeren problemleri çözmek ve daha isabetli karar vermek için kullanılmaktadır. Bu yöntemle, karmaşık problemler hiyerarşilere ayrıştırılıp her faktör ayrı ayrı ve bir bütün olarak sentezlenmektedir. Şekil 7’de AHY’nin çalışma prensibi gösterilmektedir.



Şekil 7: AHY çalışma prensibi (Yap vd., 2018)

Öncelikle, YVİH'nin arsa değerini etkilediği dört ana faktör; “İrtifak/Parsel Alanı”, “İmar Hakkı Kısıtlaması”, “YVİH'nin Geçiş Şekli” ve “Konut-Hat Mesafesi” olarak seçilmiştir. Ana faktörlerin altında 29 alt faktör belirlenmiştir. Çalışma kapsamında bir hiyerarşik yapı oluşturulmuş ve Şekil 8’de gösterilmiştir.



Şekil 8: Karar verme sürecinin hiyerarşik yapısı

“İrtifak/Parsel Alanı” faktörü irtifak alanının parsel alanına oranını ifade etmektedir. Bu başlık altında 6 alt faktör oluşturulmuş ve parsel alanının büyüklüğüne göre irtifakın etkisi irdelenmiştir. İrtifak, küçük parseldeki hakları (örnek: imar

hakkı) büyük parselde göre daha fazla sınırlandırdığı için küçük yüzölçümlü parselin değeri daha fazla düşmektedir. Bu sebeple, parsel alanları en az $<500 \text{ m}^2$ ve en fazla $>5000 \text{ m}^2$ olmak üzere 6 faktöre bölünmüş ve ayrı ayrı etki katsayıları hesaplanmıştır.

“İmar Hakkı Kısıtlaması” faktörü, YVİH’nin parselin imar hakkının % kaçını kısıtladığıyla ilgilidir. Örnek olarak; 5 kat imar hakkı olan parsel üzerinden geçen YVİH, EKAT yönetmeliğindeki yaklaşım mesafeleri sebebiyle parsel üzerindeki bu hakkı 3 kata kadar sınırlandırmıştır. Böylece parselin imar hakkı %40 kısıtlanmıştır. “YVİH’nin Geçiş Şekli” faktörü, bir YVİH’nin parselden geçiş şeklinin (köşesinden, ortasından, vb.) taşınmazda oluşturduğu değer düşüklüğüdür. “Konut-Hat Mesafesi” faktörü, YVİH’ye olan yakınlıktan kaynaklanan görsel etki, hatların düşme korkusu, cızırtı, uğultu, vb. sebeplerle parsel üzerindeki konutun değerinin düşmesidir. Burada, parsel üzerindeki konutun YVİH’ye olan mesafesi 8 alt faktöre ayrılmıştır. En uzak mesafe 100 m olarak seçilmiştir. Çalışmada belirlenen faktörler AHY ile ağırlıklandırılmış ve otomasyon modelinin arayüz yazılımı yapılmıştır.

3.2 Faktörlerin Ağırlıklandırılması ve Arayüz Yazılımı

Ana ve alt kriterlerin birbirlerine göre etki derecelerini belirlemek için ikili karşılaştırma matrisleri oluşturulmuştur. Her bir kriterin irtifak bedelinin tespitindeki ağırlık değerleri hesaplanmış, bu değerler Tablo 1 ve Tablo 2’de verilmiştir.

Tablo 1: Ana kriterlerin ağırlık değerleri

	Kriter	Ağırlık Değeri
Ana Kriter CR=0.022<0.1	İrtifak/Parsel Alanı	0.25
	İmar Hakkı Kısıtlaması	0.30
	YVİH’nin Geçiş Şekli	0.25
	Konut-Hat Mesafesi	0.20

AHY ile belirlenen faktörlerin ağırlık değerleri entegre edilerek bir model oluşturulmuştur. Node.js, Electron, TypeScript, React, Ant Design ve Webpack kullanılarak yazılımın arayüzü yapılmıştır. YVİH’nin parsel üzerinden geçiş şeklinin kod yazım örneği Şekil 9’da gösterilmiştir. Oluşturulan otomasyon modeli; üzerinden YVİH geçen parselin boyutu, parsel üzerindeki irtifakın alanı, YVİH’nin parselin imar hakkını kısıtlayıp kısıtlamaması, YVİH’nin parsel üzerinden geçiş şekli ve parsel üzerindeki konutun YVİH’ye uzaklığı faktörlerini kullanarak değer düşüklüğü oranını ve irtifak bedelini otomatik olarak hesaplamaktadır.

```
const p3 = AnaAgirliklar.G11 / 10;
const a3 = () => {
  let Key = { Letter: '!', Number: -1 };

  const E18 = valE18_IrtifakSekli;
  if (E18 == IrtifakGecisSekli.A_Kosesinden) Key = { Letter: 'J', Number: 9 };
  else if (E18 == IrtifakGecisSekli.B_KosedanBolerek) Key = { Letter: 'J', Number: 10 };
  else if (E18 == IrtifakGecisSekli.C_CaprazBolerek) Key = { Letter: 'J', Number: 11 };
  else if (E18 == IrtifakGecisSekli.D_Kenarindan) Key = { Letter: 'J', Number: 12 };
  else if (E18 == IrtifakGecisSekli.E_OrtadanBolerek) Key = { Letter: 'J', Number: 13 };
  else Key = { Letter: '!', Number: -1 };

  return AgirlikGecisSekli[Key.Letter + Key.Number] || 0.0;
}();
const s3 = p3 * a3;
setValFGecisSekli((isNaN(s3) || s3 < 0) ? 0 : s3);
```

Şekil 9: İrtifak geçiş şekli kod yazım örneği

Tablo 2: Alt kriterlerin ağırlık değerleri

Ana Kriter	Kriter	Ağırlık Değeri
İrtifak/Parsel Alanı CR=0.017<0.1	< 500 m ²	0.20
	500-1000 m ²	0.19
	1000-2000 m ²	0.17
	2000-3000 m ²	0.16
	3000-5000 m ²	0.14
	> 5000 m ²	0.14
İmar Hakkı Kısıtlaması CR=0.014<0.1	< %100	0.21
	< %90	0.18
	< %80	0.15
	< %70	0.12
	< %60	0.09
	< %50	0.07
	< %40	0.06
	< %30	0.05
	< %20	0.04
	< %10	0.03
YVİH'nin Geçiş Şekli CR=0.007<0.1	Köşeden	0.08
	Köşeden bölerek	0.14
	Ortadan çapraz bölerek	0.31
	Kenarından	0.17
	Ortasından bölerek	0.29
Konut-Hat Mesafesi CR=0.024<0.1	≤ 5 m	0.24
	≤ 10 m	0.21
	≤ 15 m	0.19
	≤ 20 m	0.13
	≤ 30 m	0.10
	≤ 40 m	0.07
	≤ 60 m	0.04
≤ 100 m	0.02	

YVİH Etki-Değer Otomasyonu başlatıldığında ana pencere üzerinde Şekil 10'daki gibi 5 bölüm görünmektedir. İlk 3 bölümde, taşınmaz, pilon, irtifak ve konutla ilgili bilgiler kullanıcılar tarafından girilecektir. Pilon alanı kutucuğu tercihlidir (opsiyonel). Taşınmaz üzerinde pilon varsa bu kutucuğa pilon alanı girilir, yoksa bu alan boş bırakılır veya 0 (sıfır) yazılır. İrtifakın taşınmazdan geçiş şeklini seçmek için "Şekil Seç" bölümü tıklanır. 5 adet geçiş şekli görüntüsü ana ekranda Şekil 11'deki gibi görünür. Sonra bu ekranda uygun geçiş şekli seçilir. Her geçiş şeklinin etkisi irtifak bedeline farklı ağırlıklarda ve otomatik olarak yansımaktadır.

Şekil 10: Otomasyon ana pencere görünümü

Şekil 11: Otomasyon irtifakın geçiş şekli işlemi

Ana pencerede parselin imar hakkının % kaçınının kısıtlandığı bilgisi otomasyona girilmelidir. Kısıtlama yoksa bu alan boş bırakılır veya 0 (sıfır) yazılır. İlgili parsel üzerinde konut varsa, konutun değeri ve YVIH'ye uzaklık bilgisi otomasyona girilmelidir. Konut yoksa bu bölümdeki switch butonu tıklanarak üçüncü bölüm pasif hâle getirilmelidir. Parsel üzerinde birden fazla konut varsa, her konutun hatta mesafesinin ortalaması alınarak YVIH'ye uzaklık bilgisi girilmelidir. İlgili çalışmaların bazılarında, YVIH'ye 100 m'den fazla uzaklıkta olan konutların hatlardan çok az etkilendiği veya hiç etkilenmediği tespit edilmiştir (Callanan, 2013; Thomas & Welke, 2017). Başka bir çalışmada ise, YVIH'ye 200 m'den uzaktaki taşınmazlarda olumsuz etkinin tamamen yok olduğu belirlenmiştir (Papinsaari, 2014). Bilirkişiler, gayrimenkul

değerleme uzmanları ve akademisyenlerle yapılan görüşmeler ile incelenen akademik yayınlar sonucunda, otomasyon modelinde konutun YVİH'ye mesafesi en fazla 100 m seçilmiştir. Bu otomasyon, YVİH'ye en fazla 100 m mesafede olan konutlarda olan değer düşüklüğü oranı ve irtifak bedelini hesaplamaktadır. YVİH'nin konuta uzaklığının 100 m'den sonra bir etkisinin olmadığı kabul edilmiştir. Girilen bütün bilgilere göre, faktörlerin irtifak bedeline etkisini gösteren ağırlıklar (% şeklinde) otomatik olarak hesaplanmakta ve ana ekranda eş zamanlı olarak gösterilmektedir. Son bölümde ise, parselde meydana gelen "Değer Düşüklüğü Oranı" ve "İrtifak Bedeli" eş zamanlı olarak hesaplanmaktadır. Parsel üzerinde pilon alanı varsa, pilon alanının mülkiyet bedeli de irtifak bedeline otomatik olarak eklenmektedir.

4. Bulgular ve Tartışma


İrtifak bedelini tespit etmek için hazırlanan bilirkişi raporlarında standart bir hesaplama yöntemi bulunmamaktadır. Taşınmazdaki değer düşüklüğüne sebep olan faktörler birçok raporda farklılık göstermektedir. Ayrıca, bu faktörlerin taşınmaz değerine ne kadar etki edeceğini karar verme yetkisi tamamen bilirkişiye bırakılmıştır. Standart bir hesaplama formülü olmadan bilirkişilerin adil bir değerlendirme yapması pek mümkün değildir. Bunun sonucunda, çoğu raporda gerçek irtifak bedelinin üstünde veya altında hesaplama yapılmaktadır. Bu haksız bedel hesaplamalarını önlemek için geliştirilen irtifak bedel tespit modeli, sağlıklı ve güvenilir sonuç vermesi için bilirkişi raporlarıyla test edilmiştir. Farklı kişilerin hazırladığı bu raporlar, Trabzon, Artvin, Amasya, İzmir, Antalya, Afyon, İstanbul, Erzurum, Şanlıurfa ve Kahramanmaraş illerinden toplanmıştır. Bilirkişi raporlarında tespit edilen Değer Düşüklüğü Oranları (DDO) ve İrtifak Bedelleri (İB), oluşturulan otomasyon modelinde tekrar hesaplanmıştır. Raporlardaki irtifak bedellerinin eksik veya fazla ödenen miktarları ve yanılma payları otomasyon programında elde edilen sonuçlarla karşılaştırılmıştır. 10 adet rapora ait olan bu veriler Tablo 3 ve Şekil 12'de gösterilmiştir.

Tablo 3: Değer düşüklüğü oranları, irtifak bedelleri ve yanılma payları

Bilirkişi Raporu	Bilirkişi Raporunda		Modelde		Yanılma Miktarı		
	DDO	İB (TL)	DDO	İB (TL)	Eksik (TL)	Fazla (TL)	Yüzde (%)
1	0.3349	22 409.92	0.2237	15 089.17		7 320.75	48.52
2	0.0100	13 869.23	0.0348	48 264.93	-34 395.70		-71.26
3	0.0842	122 918.87	0.0634	93 041.16		29 877.71	32.11
4	0.0200	30 048.17	0.0642	92 833.54	-62 785.37		-67.63
5	0.0697	136 494.45	0.0489	96 350.82		40 143.63	41.66
6	0.0050	15 817.77	0.0287	82 168.31	-66 350.54		-80.75
7	0.0200	15 287.57	0.1080	82 552.88	-67 265.31		-81.48
8	0.0100	34 660.71	0.0655	224 481.32	-189 820.61		-84.56
9	0.0666	143 313.27	0.0472	102 017.80		41 295.47	40.48
10	0.2404	1 418 013.38	0.2051	1 209 794.28		208 219.10	17.21

Tablo 3'te görüldüğü üzere, oluşturulan modele göre hesaplanan değer düşüklüğü oranları ve irtifak bedelleri ile bilirkişi raporlarında yer alan oran ve bedeller arasında farklılıklar vardır. Otomasyon modeli, hesaplama yaparken çalışmada belirlenmiş faktörleri dikkate almakta ve her faktörü etki katsayısına göre taşınmaz değerine yansıtılmaktadır. Böylece, her parsel için değer düşüklüğü oranı objektif olarak hesaplanmaktadır. Ancak, kanunlarda belirlenmiş faktörler mevcut olmadığı için bilirkişiler kendi belirledikleri faktörlere göre hesaplama yapmaktadır. Bu faktörlerin taşınmaz değeri üzerindeki etkisinin ne kadar olacağı da yine bilirkişinin takdirine bırakılmıştır. Standart bir hesaplama yönteminin olmayışı, benzer

özelliklere sahip irtifak ve taşınmazlar için hazırlanmış iki rapordaki değerler arasında büyük farklılıklar ortaya çıkarmaktadır. Önerilen otomasyon modeliyle bu farklılıkların en aza indirilmesi hedeflenmektedir.

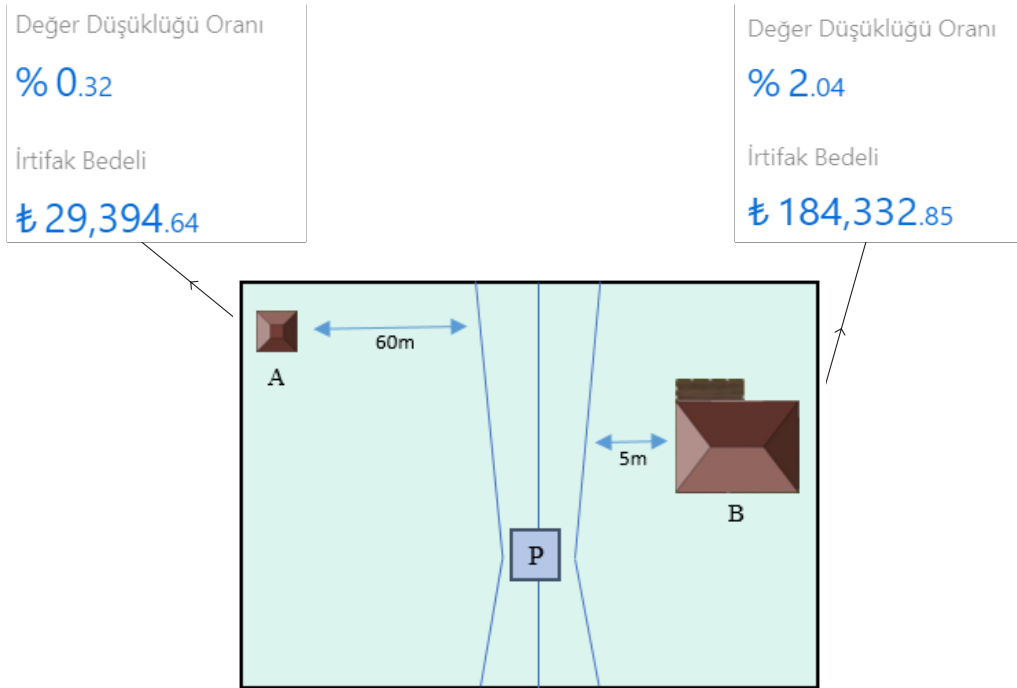


Şekil 12: Model ve bilirkişi raporuna göre değer düşüklüğü oranı ve irtifak bedeli grafiği

Aşağıda YVİH faktörlerinin taşınmaz değeri üzerindeki etkisini ayrı ayrı göstermek için iki örnek seçilmiş ve otomasyon kullanılarak değer düşüklüğü oranları ve irtifak bedelleri hesaplanmıştır.

4.1 Örnek Uygulama 1: Konutun YVİH'ye Yakınlık Etkisi


Şekil 13'te görülen 600 metrekarelik arsanın m² değeri 500 TL'dir ve arsa üzerinde bütün özellikleri aynı olan iki konut bulunmaktadır. A ve B konutlarının ikisi de 6 milyon TL değerinde olup konutların YVİH'ye mesafesi sırasıyla 60 m ve 5 m'dir. Otomasyon modeliyle yapılan hesaplamalarda, sadece YVİH'ye olan mesafeler göz önünde bulundurularak değer düşüklüğü oranı ve irtifak bedeli hesaplanmıştır. B konutunun irtifak bedeli A konutunununkinden yaklaşık olarak 155 bin TL daha fazla çıkmıştır.



Şekil 13: Konutun YVİH'ye uzaklığı

4.2 Örnek Uygulama 2: İmar hakkının sınırlandırılması

Şekil 14’te görüldüğü gibi, parselde 4 katlı binanın (A) imar hakkı vardır. YVİH geçmesiyle konut-hat arası yaklaşım mesafesi EKAT Yönetmeliği’ndeki sınırları aştığı için, bu hak 2 kat (B) ile sınırlandırılmıştır. Parseldeki imar hakkı %50 oranında sınırlandırılmıştır. İnşasına izin verilmeyen 2 kat için irtifak bedeli hesaplanarak taşınmaz sahibine ödenmelidir. Otomasyon modelinde bu örnek için irtifak bedeli hesaplanmış ve sonuç Şekil 14’te gösterilmiştir.



Şekil 14: İmar hakkının kısıtlanması

5. Sonuç ve Öneriler

İrtifak bedeli tespiti için hazırlanan bilirkişi raporlarının çoğunda, hat-direk teması, hattın kopması, direk devrilmesi, vb. faktörlerin can ve mal güvenliğini azalttığı belirtilmektedir. Bu faktörler, üzerinden irtifak geçen taşınmazda bir değer kaybına sebep olmaktadır. Bundan dolayı, bilirkişi raporlarında değer düşüklüğü oranı ve irtifak bedeli hesaplanmaktadır. Ancak, bu hesaplamalar arasında önemli farklılıklar söz konusudur.

TEİAŞ’ın 2022 yılı faaliyetlerinin toplam bütçesi 12 milyar 800 milyon TL’dir. Bu ödeneğin %15’i (yaklaşık olarak 2 milyar TL) kamulaştırma işlemleri için ayrılmaktadır (TEİAŞ, 2022). Bu oran, irtifak kamulaştırma işlemlerinin TEİAŞ faaliyetlerinde önemli bir paya sahip olduğunu göstermektedir. Kamuya ait olan bu bütçeden irtifak hakkı tesis edilecek taşınmazın sahiplerine ödenecek olan irtifak bedeli, taşınmaza getirilen yük ile doğru orantılı olmalıdır. Herhangi bir yasal bir dayanak mevcut olmadığından, irtifak bedeli belirlenirken Yargıtay yerleşik içtihatlarından yararlanılmaktadır. Ancak, bedel belirlenirken genellikle içtihatlardaki en yüksek değer düşüklüğü oranı esas alındığından, irtifak bedelleri gerçek değerinden uzak kalmaktadır.

Çalışmada, irtifak bedeline etki eden faktörler ve bu faktörlerin taşınmaz değerine etki ağırlıkları belirlenerek YVİH etki-değer otomasyon programı oluşturulmuştur. Bu programda; YVİH’nin üzerinden geçtiği parselin alanı, parselin imar hakkının kısıtlanması, hattın parsel üzerinden geçiş şekli ve (varsa) parsel üzerindeki konutun YVİH’ye mesafesi faktörleri dikkate alınarak değer düşüklüğü oranı ve irtifak bedeli hesaplanmaktadır. Bu otomasyon yazılımıyla, faktörlerin çeşitleri ve etki ağırlıkları bilirkişiye göre değişiklik göstermeyecek ve objektif bir hesaplama yöntemi sağlanmış olacaktır. Benzer parsel ve irtifaka ait bilirkişi raporları arasındaki farklılıklar en aza indirilerek taşınmaz sahiplerine daha gerçekçi irtifak bedelleri ödenebilecektir.

İrtifak bedel tespitindeki sorun ve ihtilaflar ülkeden ülkeye değişmektedir. Ülkelerin yasal merci ve süreçlerindeki farklılıklar,

YVİH'in farklı toplumlardaki algısı, ülkelerin ekonomik düzeyleri, vb. etkenler, sorun ve ihtilafların çözümünde kullanılan veri setlerinin ve değerlendirme yaklaşımlarının değişkenlik göstermesine sebep olmaktadır. Bugüne kadar yapılmış olan çalışmaların çoğunda olduğu gibi, mevcut çalışmada da anket uygulanıp istatistik programlarından yararlanılarak farklı bir veri seti oluşturulmuştur. Bu farklılıktan dolayı, çalışma sonuçlarının öncekilerle karşılaştırılması anlamlı olmayacaktır. İrtifak bedelinin gerçek değerine en yakın şekilde belirlenebilmesi için her ülkenin kendi yasal ve sosyo-ekonomik etkenlerini de dikkate alan bir anket uygulanmalı ve elde edilen verilere göre bir değerlendirme yapılmalıdır. Bu kapsamda mevcut çalışma, Türkiye'de standart bir irtifak bedeli belirlemeye yönelik ve ankete dayalı olarak yapılmış ilk örnektir.

Oluşturulan otomasyon modeli, parsel, konut ve irtifakla ilgili daha fazla faktör eklenerek geliştirilebilir. Örnek vermek gerekirse, parsel üzerinde bulunan her bir konut için; YVİH'ye uzaklık, pılona uzaklık, pilonu görme derecesi (pilonun 3/4'ünü görmesi, vb.), hattı görme derecesi, hattı ve/veya pilonu konutun hangi cephesinden (ön, arka, yan) gördüğü, düşey doğrultuda hatta mesafesi, vb. faktörlerin otomasyona eklenmesiyle irtifak bedelleri daha hassas olarak hesaplanabilir. Ayrıca, otomasyon programıyla coğrafi bilgi sistemleri entegre edilebilir, her bir parselin grafik verisinin değişimine bağlı olarak değer düşüklüğü oranı ve irtifak bedelleri hesaplanabilir.

Yazar Katkısı

Seda Nur Marabaoğlu: Fikir, Tasarım, Literatür taraması, Veri Toplama, Analiz ve yorumlama, Denetleme, Yazım.
Bayram Uzun: Fikir, Tasarım, Denetleme, Makale değerlendirme.

Çıkar Çatışması Beyanı

Yazarlar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Akinjare, O. A., Oluwunmi, A. O., & Iroham, O. C. (2012). Impact of HVOTLs on residential property rental values in high-brow Lagos metropolis. *Ethiopian Journal of Environmental Studies and Management*, 5(1), 56-63.
- Akinjare, O. A., Ogumba, O. A., Ayedun, C. A., & Iroham, C. O. (2013). Disamenity hazards and rental values in surulere, lagos metropolis: a perceptual study of power lines. *Ethiopian Journal of Environmental Studies and Management*, 6(1), 96-103.
- Bond, S., & Hopkins, J. (2000). The Impact of Transmission Lines of Residential Property Values: Results of Case Study in a Suburb of Wellington. *Pacific Rim property research journal*, 6(2), 53.
- Bottemiller, S. C., & Wolverson, M. L. (2013). The Price Effects of HVTLs on Abutting Homes. *Appraisal Journal*, 81(1).
- Bunch, K. J., Swanson, J., Vincent, T. J., & Murphy, M. F. G. (2015). Magnetic fields and childhood cancer: an epidemiological investigation of the effects of high-voltage underground cables. *Journal of Radiological Protection*, 35(3), 695.
- Callanan, J. (2010). An update on the latest literature – the effect of high voltage transmission lines on property values. *Proceedings from the 16th Annual Pacific Rim Real Estate Society Conference*. Wellington, New Zealand.
- Callanan, J. (2013). A contingent valuation approach to the valuation of high voltage transmission lines. *Proceedings of the 19th Annual Pacific Rim Real Estate Society Conference*. Melbourne, Australia.
- Callanan, J. (2017). Is the effect of high voltage transmission lines undervalued?. *International Journal of Housing Markets and Analysis*, 10(2), 221-230.
- Carll, C. D. (1956). Valuation of a power line right of way. *The Appraisal Journal*, 24, 248-265.
- Chalmers, J. A. (2012). High-Voltage Transmission Lines and Rural, Western Real Estate Values. *Appraisal Journal*, 80(1), 30-45.
- Colwell, P. F. (1990). Power lines and land value. *The Journal of Real Estate Research*, 117-127.
- Delaney, C. J., & Timmons, D. (1992). High voltage power lines: do they affect residential property value?. *The Journal of Real Estate*

Research, 315-329.

- Des Rosiers, F. (2002). Power lines, visual encumbrance and house values: a microspatial approach to impact measurement. *The Journal of Real Estate Research*, 23(3), 275-302.
- Devine-Wright, P. (2013). Explaining “NIMBY” objections to a power line: The role of personal, place attachment and project-related factors. *Environment and behavior*, 45(6), 761-781.
- Döner, F., & Kaya, E. (2021). Enerji nakil hattı projelerinin uygulanmasında arazi mülkiyetinin kazanılması sürecinin değerlendirilmesi. *Geomatik*, 6(3), 189-197.
- Elliott, P., & Wadley, D. (2012). Coming to terms with power lines. *International Planning Studies*, 17(2), 179-201.
- Gallimore, P., & Jayne, M. R. (1999). Public and professional perceptions of HVOTL risks: the problem of circularity. *Journal of Property Research*, 16(3), 243-255.
- Gervasi, F., Murtas, R., Decarli, A., & Russo, A. G. (2019). Residential distance from high-voltage overhead power lines and risk of Alzheimer’s dementia and Parkinson’s disease: a population-based case-control study in a metropolitan area of Northern Italy. *International Journal of Epidemiology*, 48(6), 1949-1957.
- Giaccaria, S., Frontuto, V., & Dalmazzone, S. (2010). Who’s afraid of power lines? Merging survey and GIS data to account for spatial heterogeneity. *Department of Economics, “S. Cognetti de Martiis”, Università di Torino, working paper N 2/2010*.
- Ignelzi, P., & Priestley, T. (1991). A Statistical Analysis of Transmission Lines Impacts in Six Neighbourhoods. *Pacific Consulting Services, Albany, CA*.
- Jackson, T. O., Pitts, J., & Norwood, S. (2012). The Effects of High Voltage Electric Transmission Lines on Commercial and Industrial Properties. *American Real Estate Society Annual Meeting*. St. Petersburg, Florida.
- Jain, N., Chileshe, R. A., Muwowo, F. M., & Mwewa, M. (2019). Perception effects of high voltage transmission (HVT) lines on residential property values: Cases of Chalala, Libala South and Kamwala South Areas of Lusaka City-Zambia. *Real Estate Management and Valuation*, 27(3), 31-41.
- Ju, H.C., & Yoo, S.H. (2014). The environmental cost of overhead power transmission lines: the case of Korea. *Journal of Environmental Planning and Management*, 57(6), 812-828.
- Kheifets, L., Ahlbom, A., Crespi, C. M., Feychting, M., Johansen, C., Monroe, J., Murphy, M.F.G., Oksuzyan, S., Preston-Martin, S., Roman, E., Saito, T., Savitz, D., Schüz, J., Simpson, J., Swanson, J., Tynes, T., Verkasalo, P., & Mezei, G. (2010). A pooled analysis of extremely low-frequency magnetic fields and childhood brain tumors. *American journal of epidemiology*, 172(7), 752-761.
- Kroll, C. A., & Priestly, T. (1992). *The effects of overhead transmission lines on property values: a review and analysis of the literature*. The Institute.
- Kung, H., & Seagle, C. F. (1992). Impact of power transmission lines on property values: a case study. *The Appraisal Journal*, 60(3), 413-418.
- Marabaoğlu, S. N., & Uzun, B. (2019). Yüksek voltajlı iletim hatları ve taşınmaz değeri. *TMMOB Harita ve Kadastro Mühendisleri Odası 17. Türkiye Harita Bilimsel ve Teknik Kurultayı*. Ankara.
- Navrud, S., Ready, R. C., Magnussen, K., & Bergland, O. (2008). Valuing the social benefits of avoiding landscape degradation from overhead power transmission lines: Do underground cables pass the benefit–cost test?. *Landscape research*, 33(3), 281-296.
- Papinsaari, H. (2014). *Voimalinjan vaikutus haja-asutusalueilla olevien asuin-ja lomatonntien hintoihin* (Yüksek lisans tezi).
- Pitts, J. M., & Jackson, T. O. (2007). Power lines and property values revisited. *The Appraisal Journal*, 75(4), 323.
- Priestley, T., & Evans, G. W. (1996). Resident perceptions of a nearby electric transmission line. *Journal of Environmental Psychology*, 16(1), 65-74.
- Rotimi, A., & Joseph, O. (2014). The Impact of High Voltage Power Lines on Residential Property Values in Selected Parts of Lagos State. *Journal of International Academic Research for Multidisciplinary*, 443-453.
- Seiler, M. (2014). Power lines and perceived home prices: Isolating elements of easement rights and noise pollution. *Journal of Sustainable Real Estate*, 6(2), 47-61.
- Sermage-Faure, C., Demoury, C., Rudant, J., Goujon-Bellec, S., Guyot-Goubin, A., Deschamps, F., Hemon, D., & Clavel, J. (2013). Childhood leukaemia close to high-voltage power lines—the Geocap study, 2002–2007. *British journal of cancer*, 108(9), 1899-1906.
- Sims, S. (2005). Power lines and house prices: real versus perceived impacts. *ENHR Conference*. Slovenia.
- Sims, S., & Dent, P. (2005). High-voltage overhead power lines and property values: a residential study in the UK. *Urban Studies*, 42(4),

665-694.

- Sims, S., Dent, P., & Ennis-Reynolds, G. (2009). Calculating the cost of overheads: the real impact of HVOTLs on house price. *Property Management*, 27(5), 319-347.
- Sims, S., & Dent, P. (2013). HVOTLs in the UK. *Towers, Turbines and Transmission Lines: Impacts on Property Value*, 55-79.
- Soini, K., Pouta, E., Salmiovirta, M., Uusitalo, M., & Kivinen, T. (2011). Local residents' perceptions of energy landscape: the case of transmission lines. *Land use policy*, 28(1), 294-305.
- Solum, C. L. (1985). Transmission line easement effect on rural land in northwest Wisconsin. *International Right of Way Association*, 14-18.
- Tatos, T., Glick, M., & Lunt, T. A. (2016). Property value impacts from transmission lines, subtransmission lines, and substations. *The Appraisal Journal*, 84(3), 205.
- TEİAŞ, (2022). *2022 Yılı Faaliyet Raporu*. Türkiye Elektrik İletim Anonim Şirketi Genel Müdürlüğü Ankara.
- Tempesta, T., Vecchiato, D., & Girardi, P. (2014). The landscape benefits of the burial of high voltage power lines: A study in rural areas of Italy. *Landscape and Urban Planning*, 126, 53-64.
- Thomas, C., & Welke, G. (2017). The Effect of HVTLs on Property Values: An Event Study. *International Real Estate Review*, 20(2).
- Wadley, D., Elliott, P., & Han, J. H. (2017). Modelling homeowners' reactions to the placement of high voltage overhead transmission lines. *International Planning Studies*, 22(2), 114-127.
- Wyman, D., & Mothorpe, C. (2018). The pricing of power lines: A geospatial approach to measuring residential property values. *The Journal of Real Estate Research*, 40(1), 121-153.
- Yap, J. Y., Ho, C. C., & Ting, C. Y. (2018). Analytic Hierarchy Process (AHP) for business site selection. *AIP Conference Proceedings* (Vol. 2016, No. 1). AIP Publishing.
- Yılmaz, M., & Alkan, R. M. (2022). Yüksek Voltajlı Elektrik Enerjisi İletim Hattı Projelerinde İrtifak Kamulaştırması. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 22(6), 1353-1367.

ESRI Land Cover ve Dynamic World arazi örtüsü verilerinin karşılaştırılması: Kıbrıs Adası örneği

Ömer Gökberk Narin^{1*} 

¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyon, Türkiye.

Öz: Arazi Kullanımı/Arazi Örtüsü (AK/AÖ) takibi, değişimlerin belirlenmesi insan ve çevresi arasındaki ilişkinin anlaşılması açısından oldukça önemlidir. Uzaktan algılama teknolojilerinin gelişmesi ile birlikte AK/AÖ lokal ve küresel ölçekte takibi daha kolay hale gelmiştir. Bununla birlikte uzaktan algılama verilerinin sınıflandırılmasında birçok sınıflandırma algoritması ve yöntem geliştirilmiştir ve geliştirilmeye devam etmektedir. Sınıflandırma algoritmalarının ve yöntemlerin birbirine karşı avantaj ve dezavantajları bulunmaktadır. Bununla birlikte AK/AÖ tespiti lokal ve küresel ölçekte kullanılabilir. Bu çalışmada küresel ölçekte ücretsiz olarak servis edilen ESRI Land Cover ve Dynamic World verileri karşılaştırılmıştır. Bu iki veri de sınıflandırma için Sentinel-2 görüntüleri kullanılmışlardır ve 10 m çözünürlükte AK/AÖ verisi servis etmektedir. Karşılaştırmada Akdeniz'in önemli bir adası olan Kıbrıs adası ele alınmıştır. Karşılaştırma için öncelikle iki veri arasındaki tutarlılığa bakılmıştır. Ardından oluşturulan kontrol noktaları ile hata matrisleri oluşturulmuştur ve genel doğruluklarına bakılmıştır. İki veri arasında su sınıfında %95, tarım arazileri sınıfında %78, yapılaşmış alan sınıfında %79, ağaçlar sınıfında %97, çıplak arazi sınıfında %85 ve sulu bitki örtüsü sınıfında %50 benzerlik bulunmaktadır. Genel doğruluklarına bakıldığında ESRI Land Cover verisi %83.5 iken Dynamic World verisi %84.5 doğruluk vermiştir. Sonuçlar incelendiğinde her iki verinin Kıbrıs adasının AK/AÖ takibinde kullanılabilir olduğu görülmektedir.

Anahtar Sözcükler: Arazi kullanımı/Arazi örtüsü, ESRI Land Cover, Dynamic World, Kıbrıs

Comparison of ESRI Land Cover and Dynamic World: The case of Cyprus Island

Abstract: Monitoring of Land Use/Land Cover (LU/LC) and determination of changes are very important in terms of understanding the relationship between human and the environment. With the development of remote sensing technologies, it has become easier to monitor LU/LC at local and global scales. However, many classification algorithms and methods have been developed and continue to be developed in the classification of remote sensing data. Classification algorithms and methods have advantages and disadvantages against each other. However, the detection of LULC can be used locally and globally. In this study, ESRI Land Cover and Dynamic World data, which are freely available on a global scale, were compared. Both of these data utilize Sentinel-2 imagery for classification and provide 10 m resolution LU/LC data. Cyprus island, an important island in the Mediterranean Sea, is considered in the comparison. For the comparison, firstly the consistency between the two data was analysed. Then, error matrices were created with the control points and their overall accuracy was analysed. There is 95% similarity in the water class, 78% in the crops class, 79% in the built area class, 97% in the trees class, 85% in the bare ground class, and 50% in the flooded vegetation class. Considering the general accuracy, ESRI Land Cover data gave an accuracy of 83.5% while Dynamic World data gave an accuracy of 84.5%. When the results are analysed, it is seen that both data can be used in the monitoring of LULC of the Cyprus island.

Keywords: Land use/Land cover, ESRI Land Cover, Dynamic World, Cyprus

1. Giriş

Geçmişten günümüze insanlar yaşadıkları bölgeleri kendi ihtiyaçları doğrultusunda kullanmışlardır. Zamanla artan nüfus ya da farklı ihtiyaçlar arazi kullanımını son derece hızlı şekilde etkilemektedir. Özellikle son 50 yılda toplumlar kırsal kesimlerde tarım yapmaktan daha çok şehirleşmeye ve endüstriyel üretime yönelmiştir. Bunun sonucu olarak da birçok tarım alanı ve ormanlık alanlar şehirleşmeye ve tarım için elverişsiz hale gelmeye başlamıştır. Bunun dolaylı bir sonucu olarak da tatlı su alanlarının azalması gibi sorunlar ortaya çıkmıştır. Bununla birlikte insanlar her ne kadar gıda ihtiyacını karşılayabilmek için birim alandan daha fazla üretim yapmaya odaklansa bile arazinin yanlış kullanımı birçok problemi ortaya çıkarmaktadır. Bu hızlı değişim ve dönüşümleri karar vericilerin ve yöneticilerin iyi bir şekilde yönetmesi gerekmektedir. Bu sebeple Arazi Kullanımı/Arazi Örtüsü (AK/AÖ) doğru bir şekilde takip edilmeli ve ona göre kararlar alınmalıdır.

AK/AÖ'nün takibi için uzaktan algılama verileri oldukça fazla kullanılmaktadır. Özellikle teknolojilerinin gelişmesiyle birlikte farklı uydu görüntüleri, Landsat-5 (Muttitanon & Tripathi, 2005; Taati vd., 2015), Landsat-7 (Akbari vd., 2006; Coulter vd., 2016), Landsat-8 (Nguyen vd., 2018) Sentinel-2 (Phiri vd., 2020) ve farklı sınıflandırma teknikleri (Chughtai vd., 2021; Talukdar vd., 2020) ile bölgesel olarak AK/AÖ belirlenebilmekte ya da değişim analizi çalışmaları yapılmaktadır.

Bununla birlikte bilgisayar kapasitelerinin artması tüm Dünya için AK/AÖ haritaları üretmeyi mümkün kılmıştır. Bu kapsamda, The International Geosphere-Biosphere Programme Data and Information System (IGBP-DIS) DISCover, Advanced Very High Resolution Radiometer (AVHRR) verisi ile 1992-1993 yıllarını kapsayan eğitimsiz kümelendirme metodu ile sınıflandırılmış 1 km çözünürlüğe sahip 17 sınıflı verisi üretilmiştir (Loveland vd., 2000). University of Maryland Arazi Örtüsü, AVHRR verisi ile 1992-1993 yıllarını kapsayan eğitilmiş karar ağacı ile sınıflandırılmış 1 km çözünürlüğe sahip 14 sınıflı AK/AÖ verisi üretilmiştir (Hansen & Reed, 2000). Global Land Cover 2000, Spot 4 verisi ile 2000 yılını kapsayan ISODATA yöntemi ile sınıflandırılmış 1 km çözünürlüğe sahip 22 sınıflı AK/AÖ verisi üretilmiştir (Bartholome & Belward, 2005). Global land cover mapping from MODIS, Terra ve aqua MODIS verisi ile 2001 ve 2010 yılını kapsayan eğitilmiş sınıflandırma ile sınıflandırılmış 500 m çözünürlüğe sahip 17 sınıflı AK/AÖ verisi üretilmiştir (Friedl vd., 2002). GLCNMO2008, Terra and aqua MODIS verisi ile 2008 yılını kapsayan eğitilmiş sınıflandırma ile sınıflandırılmış 500 m çözünürlüğe sahip 20 sınıflı AK/AÖ verisi üretilmiştir (Tateishi vd., 2014). Globeland30, Landsat TM/ETM, HJ-1, GF-1 ile 2000-2010-2020 yıllarına ait piksel ve obje tabanlı kombine edilmiş metot ile 30 m çözünürlüğe sahip 10 sınıflı AK/AÖ verisi üretilmiştir (Chen vd., 2015). ESRI, Impact Observatory ve Microsoft tarafından geliştirilen ESRI Land Cover, Sentinel-2 verisi ile 2017 yılından başlayarak derin öğrenme metodu ile yıllık 10 m çözünürlüğe sahip 10 sınıflı AK/AÖ verisi üretilmiştir (Karra vd., 2021). Google ve World Resources Institute tarafından geliştirilen Dynamic World, Sentinel-2 verisi ile 2017 yılından başlayarak derin öğrenme metodu ile sınıflandırılmış 10 m çözünürlüğe sahip 9 sınıflı AK/AÖ verisi üretilmiştir (Brown vd., 2022).

Küresel ölçekte modeller, kullanıcılar ve karar vericiler için önemli verilerdir. Ülke bazında yapılacak değişim analizleri için veri işleme sınıflandırma gibi işlemler yapılmadan AK/AÖ'ne ait bilgiler elde edilebilir. Ancak üretilen modellerin doğruluk bilgilerinin çalışılan alanda tekrar kontrol edilmesi gerekmektedir. Çünkü model doğrulukları üreticilerin kısıtlı sayıdaki veri kümesi ile elde edilmektedir ve bunu tüm dünya ölçeğinde doğru kabul etmek mümkün değildir. Bu kapsamda Yang vd. (2017) Çin'de yaptıkları çalışmada 7 farklı küresel modeli karşılaştırmışlardır. Tüm haritaların homojen alanlarda yüksek doğruluk sağladığını ancak kullanıcıların dağlar, tarım alanları gibi alanlara özellikle dikkat etmesi gerektiğini vurgulamışlardır. Ren vd. (2018) Çin'in Jiangxi ilinde yaptığı çalışmada referans data olarak 1:100 000 ölçekli 2010 yılında üretilmiş arazi kullanımı verisi kullanmışlardır. Genel doğruluğun %78'den yüksek olduğunu belirtmişlerdir. Brovelli vd., (2015) İtalya'nın 8 bölgesinde gerçekleştirdiği çalışmada CORINE arazi örtüsü verisi kullanmışlardır ve genel doğruluğu

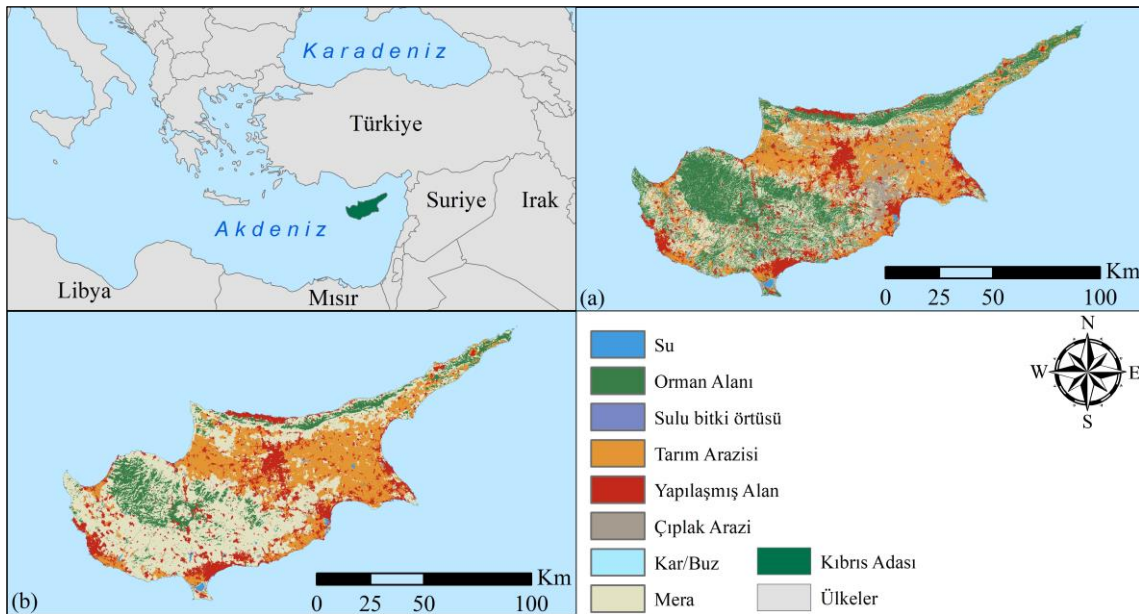
%80 üzerinde bulmuşlardır. [Brown vd. \(2022\)](#) Dynamic World verisini duyurmuş oldukları çalışmada tüm dünyada farklı veri grupları ile model doğruluğuna bakmışlardır ve %70'in üzerinde doğruluk elde etmişlerdir. [Karra vd. \(2021\)](#) geliştirdikleri ESRI Land Cover modelini Amerika Birleşik Devletleri'nin (ABD) California eyaletinde, Kosta Rika, Belçika ve Laos'ta test etmişlerdir ve genel doğruluklarını sırasıyla %85, %84, %90 ve %89 bulmuşlardır. [Venter vd. \(2022\)](#) gerçekleştirdikleri çalışmada, ESRI Land Cover, Dynamic World ve ESA's World Cover verilerini karşılaştırmışlardır. Karşılaştırmada yer doğruluğu verisi için Sentinel-2 uydu görüntüsü kullanmışlardır. Yer doğruluğu için Avrupa kıtası ve tüm Dünya için farklı veri kullanmışlardır. Tüm Dünya genelinde sonuçlara bakıldığında %75 doğrulukla ESRI Land Cover verisi, Avrupa kıtası içinse ESA's World Cover verisinin %71 doğruluk verdiğini belirtmişlerdir.

Bu çalışmada, diğer modellere göre daha güncel ve yüksek çözünürlüklü veri sunan ESRI Land Cover ve Dynamic World verileri karşılaştırılmıştır. ESRI Land Cover ve Dynamic World verilerini karşılaştırmak için çalışma alanı olarak Kıbrıs Adası seçilmiştir. Çalışma alanında iki veri arasındaki tutarlılığa ve oluşturulan kontrol noktaları ile hata matrisi oluşturularak genel doğruluklarına bakılmıştır.

2. Materyal ve Yöntem

2.1 Çalışma Alanı

Kıbrıs Adası yüzölçümü bakımından Akdeniz'in üçüncü büyük adası olup toplam 9.251 km²'lik yüzölçümüne sahiptir (Şekil 1). M.Ö. 10000'li yıllara kadar dayanan tarihi ile Akdeniz'de önemli bir yere sahiptir. Şu an adada yaklaşık 1 milyondan fazla insan yaşamaktadır. Coğrafi olarak kuzey kesimi dağlık olan adada güney ve doğu kesimlerinde göller bulunmaktadır. Bu göletlerin bazıları da tuz gölüdür. Bitki örtüsü turuncu, zeytinlik ve makidir. Bununla birlikte çam, meşe gibi ormanlık alanları da bulunmaktadır ([Koday, 1995](#)).



Şekil 1: Kıbrıs Adasının konumu. (a) Dynamic World verisine ait AK/AÖ haritası (b) ESRI Land Cover verisine ait AK/AÖ haritası. AK/AÖ haritaları yeniden sınıflandırılmış olarak kullanılmıştır.

2.2 ESRI Land Cover

ESRI Land Cover verisi 2021 yılında yayınlanmış olup ücretsiz olarak 10 m konumsal çözünürlükte sunulmaktadır ([URL-1](#)). ESRI Land Cover verilerini sınıflandırmak için evrişimli sinir ağı mimarisi kullanılmıştır. Ağı eğitmek için on arazi sınıfına

(su, ağaçlar, mera, sulu bitki örtüsü, tarım arazisi, çalılık, yapılaşmış alan, çıplak arazi, kar/buz ve bulut) ait 24.000'den fazla 5x5 km'lik eğitim görüntüsü kullanılmıştır. Sınıflandırma için Sentinel-2 (L2A) uydusunun 6 bandı (kırmızı (Band04), yeşil (Band03), mavi (Band02), Yakın Kızılötesi (Band08), Kısa Dalga Kızılötesi-1 (Band11), Kısa Dalga Kızılötesi-2 (Band12)) kullanılmıştır (Karra vd., 2021). ESRI Land Cover verisine ait sınıfların açıklamaları aşağıda verilmiştir.

1. Su (Water): Suyun sürekli olarak bulunduğu bölgeler; göller, rezervuarlar, denizler, nehirler vb.
2. Ağaçlar (Trees): Savanlar, çiftlikler, bataklıklar veya mangrovlar içindeki 15 m ya da daha uzun kalın bitki örtüsü kümeleri.
3. Çimen (Grass): Homojen çimenler ve çimenler ile kaplanmış insan eli değmemiş açık alanlar; yeşillik, bahçeler ve meralar ve açık savanlar.
4. Sulu bitki örtüsü (Flooded vegetation): Yılın büyük bir kısmında su bulunan bitki örtüsü alanları; Pirinç tarlaları, mangrovlar ve diğer yoğun su altında bulunan bahçeler.
5. Tarım arazisi (Crops): İnsanlar tarafından ekilip biçilen alanlar; mısır, buğday, soya gibi organize şekilde biçilen araziler.
6. Çalılık (Shrubs): Dikenli ve dikensiz çalılırların ve çimen tutamlarının, küçük bitki demetleri veya tek tek bitkilerin bir karışımını içeren alanlar.
7. Yapılaşmış alan (Built areas): Yapı alanları; büyük yollar, park yapıları ve konutlar; evler, yoğun köyler/kasabalar/şehirlere, asfalt yollar ve beton.
8. Çıplak arazi (Bare grounds): Tüm yıl boyunca bitki örtüsü olmayan kayalık veya çıplak topraklı alanlar; büyük kumlu alanlar, çöller ve kum tepeleri, madenler.
9. Kar/buz (Snow/Ice): Çoğunlukla dağlarda veya buzullarda kalıcı kar veya buz bulunan alanlar.
10. Bulutlar (Clouds): Arazi örtüsü bilgilerinde görülmeyen alanın bulut örtüsü.

2.3 Dynamic World

Google ve World Resources Institute tarafından hazırlanan Dynamic World verisi ücretsiz olarak 10 m konumsal çözünürlükte Google Earth Engine (GEE) üzerinden indirilebilmektedir (Brown vd., 2022). Dynamic World verisini sınıflandırmak için Tamamen Evrişimli Sinir Ağı (Fully Convolutional Neural Network) yöntemi kullanılmıştır. Model eğitimi için eğitim verisi stratejisi yarı denetimli sınıflandırmaya dayanmaktadır. Eğitim ve test verileri etiketlenmeden önce dünya 3 bölgeye ayrılmıştır. Ardından 9 sınıf (su, ağaçlar, çimen, sulu bitki örtüsü, tarım arazisi, çalılık, yapılaşmış alan, çıplak arazi, kar/buz) için görüntüler üzerinden etiketleme işlemi yapılmıştır. Sınıflandırmada Sentinel-2 görüntüleri kullanılmıştır. Ancak, Kıyı ve Aerosol (B1), Görünür ve Yakın Kızılötesi (B8A), Su buharı (B9) ve Kısa Dalga Kızılötesi (B10) bantları kullanılmamıştır (Brown vd., 2022). Dynamic World verisine ait sınıfların açıklamaları aşağıda verilmiştir.

1. Su (Water): Görüntüde su mevcuttur. Seyrek bitki örtüsü içerir veya hiç içermez, kaya çıkıntısı yoktur ve rıhtım gibi yerleşik özellikler bulunmaz. Daha önce suyla kaplanmış arazileri kapsamaz.

2. Ağaçlar (Trees): Tipik olarak kapalı veya yoğun bir gölgelik içeren, yoğun bitki örtüsünün önemli bir kümelenmesi. Çevredeki bitki örtüsünden daha uzun ve daha koyu olan pikseller (eğer başka bitki örtüsüyle çevriliyse).
3. Çimen (Grass): Homojen otlarla kaplı, çok az uzun veya bitki örtüsü olmayan açık alanlar. Ağaçlardan ve çalılıklardan farklı görünen, çim benzeri bitki örtüsünden oluşan diğer homojen alanlar. Açık bir şekilde insan eli değmemiş (yani yapılandırılmamış alan) yabancı tahıllar ve otlar.
4. Sulu bitki örtüsü (Flooded vegetation): Suyun açıkça birbirine karıştığı her türlü bitki örtüsünün bulunduğu alanlar. Görüntüde su baskını gözlemlenirse, bir alanın sular altında kaldığı varsayılmaz. Çim/çalı/ağaç/çiplak zemin karışımından oluşan, mevsimsel olarak su basan alanlar.
5. Tarım arazisi (Crops): İnsan tarafından ekilen/planlanan tahıllar, otlar ve ürünler.
6. Çalılık (Shrub and scrub): Açıkta kalan toprağı ve kayayı gösteren bir manzaraya dağılmış küçük bitki kümelerinin veya tek tek bitkilerin karışımıdır. Yoğun ormanların içindeki, ağaçlardan uzun olmadığı açıkça görülen çalılıklarla dolu açıklıklardır. Daha az yoğun yaprak örtüsü nedeniyle daha gri/kahverengi görünür.
7. Yapılaşmış alan (Built area): İnsan yapımı yapı kümeleri veya tek tek çok büyük insan yapımı yapılar. Endüstriyel, ticari ve özel binaları ve ilgili otoparkları içerir. Konut binaları, sokaklar, çimler, ağaçlar, izole konut yapıları veya bitkisel arazi örtüsüyle çevrili binaların bir karışımıdır. Ağırıklı yerleşim bölgelerinin dışındaki ana karayolu ve demiryolu ağları, park yapıları, büyük ofis binaları ve çıkmaz sokak kümeleri içeren konut geliştirmeleri de dahil olmak üzere geniş homojen geçirimsiz yüzeylerdir.
8. Çıplak arazi (Bare grounds): Çok seyrek veya hiç bitki örtüsü içermeyen kaya veya toprak alanlar. Bitki örtüsünün olmadığı veya çok az olduğu geniş kum alanları ve çöller, büyük bireysel veya yoğun toprak yol ağlarıdır.
9. Kar/buz (Snow/Ice): Tipik olarak yalnızca dağlık bölgelerde veya en yüksek enlemlerde bulunan, kalın kar veya buzdan oluşan geniş, homojen alanlar. Geniş homojen kar yağışı alanları.

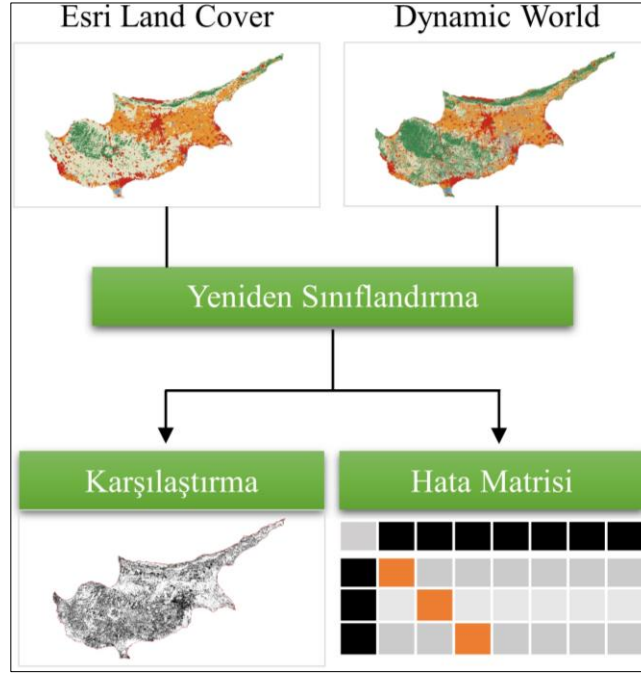
2.4 İş Akışı

Kıbrıs Adası'na ait Dynamic World ve ESRI Land Cover 2020 yılına ait veriler indirilmiştir. ESRI Land Cover modeli için (URL-1) internet adresinden Kıbrıs Adası'nı içine alan bölgeye ait pafta indirilmiştir. Dynamic World için GEE platformu kullanılarak veri indirilmiştir (URL-2). İndirilen verilerde ESRI Land Cover için 9 adet sınıf (çalılık ve çimen sınıfı yerine mera) bulunmaktadır. Bu sebeple yeniden sınıflandırma işlemi yapılarak sınıf sayıları her iki veride de eşleştirilmiştir. Kesme işlemi için Kıbrıs Adası'nın kara sınırından 100 m deniz yönünde tampon bölge oluşturularak kesilmiştir. Çalışmada elde edilen su sınıfı sonuçları sadece adada bulunan ada ve gölleri değil denize ait pikselleri de kapsamaktadır. İki veri arasında tutarlılığa bakmak için piksel bazlı karşılaştırma yapılmış ve iki veri arasında hangi sınıflarda geçiş olduğu tespit edilmiştir. Son olarak da rastgele seçilmiş 3206 adet nokta ile her iki veri için de hata matrisleri oluşturulmuş ve birçok çalışmada kullanılmış olan doğruluğa bakılmıştır (Akca & Polat, 2022; Lillesand vd., 2015; Seyrek ve Uysal, 2023; Yener vd., 2006) (Eşitlik 1).

$$\text{Genel Doğruluk} = (1/T) \sum_{i=1}^s t_{ii} \quad (1)$$

Burada; T hata matrisindeki örnek sayılarının toplamını, s hata matrisindeki satırı, t_{ii} doğru sınıflandırılmış örnekleri temsil etmektedir. Yersel veri olarak sınıflandırılmış veriden daha yüksek mekânsal çözünürlüğe sahip olan Google Earth üzerinden

2020 yılına ait uydu görüntülerinden elde edilmiştir. Genel iş akışı Şekil 2’de verilmiştir.




Şekil 2: Çalışmaya ait genel iş akışı

3. Bulgular ve Tartışma

Çalışmada öncelikle verilerde hangi sınıfta kaç piksel olduğu tespit edilmiştir. Tablo 1’e bakıldığında zaman ESRI Land Cover verisine göre en çok piksel sayısı mera en az piksel sayısı kar/buz sınıfındayken, Dynamic World verisine göre en çok piksel sayısı ağaç sınıfında en az piksel sayısı kar/buz sınıfındadır. ESRI Land Cover ile Dynamic World verileri arasında en çok mera sınıfında fark bulunmaktadır. İki veri arasındaki farkların konumsal dağılımlarına bakılmıştır. Bu konumsal dağılımlar sınıf bazlı değil benzer olan yerler ile olmayan yerler özelinde incelenmiştir (Şekil 3).

Tablo 1: Sınıflara ait piksel sayıları ve iki veri arasındaki piksel sayısı farkları

Sınıf	ESRI Land Cover	Dynamic World	Piksel Sayısı Farkı
Su	1 202 408	1 228 279	25 871
Ağaçlar	10 408 319	25 145 747	14 737 428
Sulu bitki örtüsü	23 441	47 165	23 724
Tarım arazisi	24 192 689	23 285 417	907 272
Yapılaşmış alan	13 637 219	12 369 477	1 267 742
Çıplak arazi	1 027 492	6 170 872	5 143 380
Kar/Buz	369	19 984	19 615
Mera	42 614 251	24 830 197	17 784 054



Şekil 3: ESRI Land Cover ile Dynamic World verileri arasındaki farklı piksellerin konumsal dağılımı

Dynamic World ile ESRI Land Cover verilerinde hangi sınıflar arasında geçişler olduğu alan bazında yüzdesel olarak incelenmiştir (Şekil 4). Alandaki farklılıklar Dynamic World verisinden ESRI Land Cover verisi çıkarılarak elde edilmiştir (Tablo 2). Su sınıfında iki veri arasındaki en çok değişim çıplak arazi ardından yapılaşmış alan sınıfı olarak bulunmuştur. İki veri grubunda su sınıfında %95.36 benzerlik olduğu görülmektedir. Tarım arazileri sınıfında iki veri arasındaki en çok değişim %9.7 ile çıplak arazide ardından mera sınıfında olarak bulunmuştur. Yapılaşmış alan sınıfında iki veri arasındaki en çok değişim %7.36 ile mera sınıfında ardından da tarım arazilerinde olmuştur. Mera sınıfında iki veri arasındaki en çok değişim %33.04 ile ağaçlar sınıfında ardından da tarım arazilerinde olmuştur. Ağaçlar sınıfında iki veri arasındaki en çok değişim %1.72 ile mera sınıfıyla ardından yapılaşmış alan sınıfında olmuştur. İki veri arasında en çok benzerlik olan sınıf %97.90 ile ağaçlar sınıfı olmuştur. Çıplak arazi sınıfında iki veri arasındaki en çok değişim %7.57 ile tarım arazilerinde ardından %2.84 ile su sınıfında olmuştur. Sulu bitki örtüsü sınıfında iki veri arasındaki en çok değişim %20 ile ağaçlar sınıfında ardından %13.15 ile su sınıfında gerçekleşmiştir. Kar/Buz sınıfında iki veri arasındaki en çok değişim %48.87 ile çıplak arazi sınıfında ardından %13.59 ile yapılaşmış alan sınıfında gerçekleşmiştir. İki veri grubu arasında en çok farklılık kar/buz sınıfında gerçekleşmiştir.

Tablo 2: Dynamic World ve ESRI Land Cover verilerinde bulunan sınıfların birbirleri arasındaki değişimler

Sınıflar	Değişim (%)	Sınıflar	Değişim (%)
Su-Su	95.36	Ağaçlar-Ağaçlar	97.90
Su-Ağaçlar	0.44	Ağaçlar-Su	0.00
Su-Sulu bitki örtüsü	0.16	Ağaçlar-Sulu bitki örtüsü	0.01
Su-Tarım arazileri	0.26	Ağaçlar-Tarım arazileri	0.10
Su-Yapılaşmış alan	0.73	Ağaçlar-Yapılaşmış alan	0.22
Su-Çıplak arazi	2.33	Ağaçlar-Çıplak arazi	0.03
Su-Kar/Buz	0.35	Ağaçlar-Kar/Buz	0.01
Su-Mera	0.37	Ağaçlar-Mera	1.72
Tarım arazileri-Tarım arazileri	78.15	Çıplak arazi-Çıplak arazi	85.18
Tarım arazileri-Su	0.04	Çıplak arazi-Su	2.84
Tarım arazileri-Ağaçlar	1.69	Çıplak arazi-Ağaçlar	0.28
Tarım arazileri-Sulu bitki örtüsü	0.02	Çıplak arazi-Sulu bitki örtüsü	0.04
Tarım arazileri-Yapılaşmış alan	1.99	Çıplak arazi-Tarım arazileri	7.56
Tarım arazileri-Çıplak arazi	9.70	Çıplak arazi-Yapılaşmış alan	1.97
Tarım arazileri-Kar/Buz	0.00	Çıplak arazi-Kar/Buz	0.26
Tarım arazileri-Mera	8.42	Çıplak arazi-Mera	1.87
Yapılaşmış alan-Yapılaşmış alan	79.61	Sulu bitki örtüsü-Sulu bitki örtüsü	58.15
Yapılaşmış alan-Su	0.12	Sulu bitki örtüsü-Su	14.87
Yapılaşmış alan-Ağaçlar	3.36	Sulu bitki örtüsü-Ağaçlar	22.65
Yapılaşmış alan-Sulu bitki örtüsü	0.01	Sulu bitki örtüsü-Tarım arazileri	1.49
Yapılaşmış alan-Tarım arazileri	5.30	Sulu bitki örtüsü-Yapılaşmış alan	1.11
Yapılaşmış alan-Çıplak arazi	4.23	Sulu bitki örtüsü-Çıplak arazi	1.72
Yapılaşmış alan-Kar/Buz	0.00	Sulu bitki örtüsü-Kar/Buz	0.00
Yapılaşmış alan-Mera	7.36	Sulu bitki örtüsü-Mera	13.10
Mera-Mera	50.65	Kar/Buz-Kar/Buz	33.04
Mera-Su	0.07	Kar/Buz-Su	0.00
Mera-Ağaçlar	33.04	Kar/Buz-Ağaçlar	3.34
Mera-Sulu bitki örtüsü	0.06	Kar/Buz-Sulu bitki örtüsü	0.00
Mera-Tarım arazileri	8.38	Kar/Buz-Tarım arazileri	0.00
Mera-Yapılaşmış alan	2.30	Kar/Buz-Yapılaşmış alan	13.59
Mera-Çıplak arazi	5.47	Kar/Buz-Çıplak arazi	48.87
Mera-Kar/Buz	0.03	Kar/Buz-Mera	1.17

ESRI Land Cover ve Dynamic World AK/AÖ verilerinin doğruluğunun tespitine yönelik hata matrisi Tablo 3 ve Tablo 4'te verilmiştir. ESRI Land Cover verisi çalışma sonuçlarına göre %83.5 genel doğruluğa sahiptir. ESRI Land Cover verisi ABD'nin California eyaletinde, Kosta Rika'da, Belçika'da ve Laos'ta %84 ile %90 arasında genel doğruluğa sahiptir (Karra vd., 2021). ESRI Land Cover için en yüksek kullanıcı doğruluğu %98.68 ile sulu bitki örtüsüne aittir. Sulu bitki örtüsü sınıfı çalışma alanında en az alana sahip sınıftır. Bu duruma paralel olarak kontrol noktasının az olması sebebiyle kullanıcı doğruluğu olması gerekenden daha iyi olarak tespit edilmiş olabilir. Kullanıcı doğruluğuna göre sulu bitki örtüsü sınıfından sonra sırasıyla su (%97.09), yapılaşmış alan (%91.20), tarım arazileri (%90.44), ağaçlar (%85.51), mera (%73.02) ve çıplak arazi (%64.02) sınıfları gelmektedir (Tablo 3).

Tablo 3: ESRI Land Cover verisinin hata matrisi (%)

Sınıf / Örnek	Su	Ağaçlar	Sulu bitki örtüsü	Tarım arazileri	Yapılaşmış alan	Çıplak arazi	Mera	Toplam	Kullanıcı Doğruluğu
Su	98.62	0.00	9.09	0.00	0.00	0.00	0.00	16.06	97.09
Ağaçlar	0.00	70.71	0.00	3.96	0.00	6.00	7.22	17.44	85.51
Sulu bitki örtüsü	0.39	0.00	90.91	0.00	0.00	0.00	0.00	4.74	98.68
Tarım arazileri	0.00	1.78	0.00	76.92	0.00	0.00	4.75	12.07	90.44
Yapılaşmış alan	0.00	0.00	0.00	0.00	92.39	5.04	3.80	14.54	91.20
Çıplak arazi	0.99	17.90	0.00	5.49	5.65	83.93	3.42	17.00	64.22
Mera	0.00	9.62	0.00	13.63	1.96	5.04	80.80	18.15	73.02
Toplam	100	100	100	100	100	100	100	100	T = 83.5

Dynamic World verisi çalışma sonuçlarına göre %84.6 genel doğruluğa sahiptir. Dynamic World verisi için kullanıcı doğruluğu en yüksek su sınıfıdır (%99.01). Su sınıfını kullanıcı doğruluğuna göre sırasıyla sulu bitki örtüsü (%98.16), tarım arazileri (%94.26), yapılaşmış alan (%93.19), ağaçlar (%84.74), mera (%76.50) ve çıplak arazi (%61.80) sınıfları izlemektedir (Tablo 4). ESRI Land Cover verisine göre %1.1 genel doğruluk daha iyi çıkmıştır. Kullanıcı doğrulukları bakımından her iki verinin de sonuçları birbirine yakındır. [Venter vd. \(2022\)](#) genel olarak ESRI Land Cover ve Dynamic World verilerinin mera, çıplak arazi ve sulu bitki örtüsü sınıflarında düşük doğruluğa sahip olduklarını belirtmişlerdir. Kıbrıs özelinde yapılan bu çalışmada da çıplak arazi ve mera sınıfının diğer sınıflara göre düşük doğrulukta olduğu görülmektedir.

Tablo 4: Dynamic World verisinin hata matrisi (%)

Sınıf / Örnek	Su	Ağaçlar	Sulu bitki örtüsü	Tarım arazileri	Yapılaşmış alan	Çıplak arazi	Mera	Toplam	Kullanıcı Doğruluğu
Su	98.62	0.00	3.03	0.00	0.00	0.00	0.00	15.75	99.01
Ağaçlar	0.00	78.85	0.00	5.05	0.00	8.39	7.22	19.62	84.74
Sulu bitki örtüsü	0.59	0.00	96.97	0.00	0.00	0.00	0.00	5.08	98.16
Tarım arazileri	0.00	1.33	0.00	75.82	0.00	0.00	2.28	11.42	94.26
Yapılaşmış alan	0.00	0.00	0.00	0.00	86.30	5.04	1.52	13.29	93.19
Çıplak arazi	0.79	17.46	0.00	5.49	7.61	79.14	4.18	16.66	61.80
Mera	0.00	2.37	0.00	13.63	6.09	7.43	84.79	18.18	76.50
Toplam	100	100	100	100	100	100	100	100	T = 84.6

4. Sonuçlar

Bu çalışmada 10 m çözünürlüğe sahip ücretsiz olarak servis edilen iki AK/AÖ verisi Kıbrıs Adası'nda test edilmiştir. Bu kapsamda 2020 yılına ait ESRI Land Cover ve Dynamic World verileri indirilmiştir. ESRI Land Cover verisi ([URL-3](#)) üyelik gerektirmeden internet tarayıcısından istenilen alana ait pafta ve yılı seçildikten sonra AK/AÖ verisi GeoTIFF formatında indirilebilmektedir. Dynamic World verisi de ESRI Land Cover verisi gibi ücretsizdir. Ancak Dynamic World verisinin indirilebilmesi için GEE bulut tabanlı platforma giriş yapmak gerekmektedir. Dynamic World verisinin verisi indirilmek istediğinde JavaScript diline hakim olmak gerekmektedir ([URL-4](#)). Dynamic World verisinin GEE üzerinden servis edilmesi

bazı kullanıcılar için dezavantaj oluşturabilir. ESRI Land Cover ($T = \%83.5$) ve Dynamic World ($T = \%84,6$) verilerinin Kıbrıs Adası'nda doğruluklarının birbirine yakın olduğu tespit edilmiştir. Bu doğruluklar kullanıcının yer kontrol noktası seçimine göre değişebilmektedir. Ancak bu çalışmadaki doğruluk sonuçları başka çalışmalar ile karşılaştırıldığında benzer sonuçlar elde edildiği görülmektedir (Brown vd., 2022; Karra vd., 2021). Genel doğruluğun $\%80$ üzeri olması durumunda güvenilir kabul edilmektedir (Koç & Yener, 2001). Her iki verinin de genel doğruluğu $\%80$ üzerinde olduğu için kullanılabilir olarak kabul edilebilir. Ayrıca veriler başka bölgelerde kullanılmak istendiğinde kontrol edilmesinde fayda vardır. Bununla birlikte ilerleyen çalışmalarda ESRI Land Cover ve Dynamic World verilerinin AK/AÖ değişiminde kullanılabilirliği araştırılacaktır.

Çıkar Çatışması Beyanı

Yazar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Akbari, M., Mamanpoush, A. R., Gieske, A., Miranzadeh, M., Torabi, M., & Salemi, H. R. (2006). Crop and land cover classification in Iran using Landsat 7 imagery. *International Journal of Remote Sensing*, 27(19), 4117-4135.
- Akca, S., & Polat, N. (2022). Semantic segmentation and quantification of trees in an orchard using UAV orthophoto. *Earth Science Informatics*, 15(4), 2265-2274.
- Bartholome, E., & Belward, A. S. (2005). GLC2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing*, 26(9), 1959-1977.
- Brovelli, M. A., Molinari, M. E., Hussein, E., Chen, J., & Li, R. (2015). The first comprehensive accuracy assessment of GlobeLand30 at a national level: Methodology and results. *Remote Sensing*, 7(4), 4191-4212.
- Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Hyde, S. B., Mazzariello, J., Haertel R., Ilyushchenko S., Schwehr K., Weisse M., Stolle F., Hanson C., Guinan O., Moore R., & Tait, A. M. (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific Data*, 9(1), 251.
- Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., Lu, M., Zhang, W., Tong, X., & Mills, J. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 7-27.
- Chughtai, A. H., Abbasi, H., & Karas, I. R. (2021). A review on change detection method and accuracy assessment for land use land cover. *Remote Sensing Applications: Society and Environment*, 22, 100482.
- Coulter, L. L., Stow, D. A., Tsai, Y. H., Ibanez, N., Shih, H. C., Kerr, A., Benza, M., Weeks, J. R., & Mensah, F. (2016). Classification and assessment of land cover and land use change in southern Ghana using dense stacks of Landsat 7 ETM+ imagery. *Remote Sensing of Environment*, 184, 396-409.
- Friedl, M. A., McIver, D. K., Hodges, J. C., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. H., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., & Schaaf, C. (2002). Global land cover mapping from MODIS: algorithms and early results. *Remote sensing of Environment*, 83(1-2), 287-302.
- Hansen, M. C., & Reed, B. (2000). A comparison of the IGBP DISCover and University of Maryland 1 km global land cover products. *International Journal of Remote Sensing*, 21(6-7), 1365-1373.
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use/land cover with Sentinel 2 and deep learning. *2021 IEEE international geoscience and remote sensing symposium IGARSS*, 4704-4707.
- Koç, A., & Yener, H. (2001). Uzaktan Algılama Verileriyle İstanbul Çevresi Ormanlarının Alansal ve Yapısal Değişikliklerinin Saptanması. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 51(2), 17-36.
- Koday, Z. (1995). Kuzey Kıbrıs Türk Cumhuriyeti Devleti'nin Coğrafi Özellikleri. *Atatürk Üniversitesi Türkiyat Araştırmaları Enstitüsü Dergisi*, (2), 17-45.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.

- Loveland, T. R., Reed, B. C., Brown, J. F., Ohlen, D. O., Zhu, Z., Yang, L. W. M. J., & Merchant, J. W. (2000). Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data. *International journal of remote sensing*, 21(6-7), 1303-1330.
- Muttitanon, W., & Tripathi, N. K. (2005). Land use/land cover changes in the coastal zone of Ban Don Bay, Thailand using Landsat 5 TM data. *International Journal of Remote Sensing*, 26(11), 2311-2323.
- Nguyen, H. T. T., Doan, T. M., & Radeloff, V. (2018). Applying random forest classification to map land use/land cover using Landsat 8 OLI. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 363-367.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, 12(14), 2291.
- Ren, H., Cai, G., Zhao, G., & Li, Z. (2018). Accuracy assessment of the globeland30 dataset in jiangxi province. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 1481-1487.
- Seyrek, E. C., & Uysal, M. (2023). A comparative analysis of various activation functions and optimizers in a convolutional neural network for hyperspectral image classification. *Multimedia Tools and Applications*, 1-32.
- Taati, A., Sarmadian, F., Mousavi, A., Pour, C. T. H., & Shahir, A. H. E. (2015). Land use classification using support vector machine and maximum likelihood algorithms by Landsat 5 TM images. *Walailak Journal of Science and Technology (WJST)*, 12(8), 681-687.
- Talukdar, S., Singha, P., Mahato, S., Pal, S., Liou, Y. A., & Rahman, A. (2020). Land-use land-cover classification by machine learning classifiers for satellite observations—A review. *Remote Sensing*, 12(7), 1135.
- Tateishi, R., Hoan, N. T., Kobayashi, T., Alsaaidh, B., Tana, G., & Phong, D. X. (2014). Production of global land cover data—GLCNMO2008. *Journal of Geography and Geology*, 6(3), 99-122.
- Venter, Z. S., Barton, D. N., Chakraborty, T., Simensen, T., & Singh, G. (2022). Global 10 m Land Use Land Cover Datasets: A Comparison of Dynamic World, World Cover and Esri Land Cover. *Remote Sensing*, 14(16), 4101.
- Yang, Y., Xiao, P., Feng, X., & Li, H. (2017). Accuracy assessment of seven global land cover datasets over China. *ISPRS Journal of Photogrammetry and Remote Sensing*, 125, 156-173.
- Yener, H., Ayhan, K. O. Ç., & Çoban, H. O. (2006). Uzaktan Algılama Verilerinde Sınıflandırma Doğruluğunun Belirlenmesi Yöntemleri. *Journal of the Faculty of Forestry Istanbul University*, 56(2), 71-88.
- URL-1: <https://www.arcgis.com/apps/instant/media/index.html?appid=fc92d38533d440078f17678ebc20e8e2>, (Erişim Tarihi: 31 Kasım 2023).
- URL-2: <https://developers.google.com/earth-engine/tutorials/community/introduction-to-dynamic-world-pt-1>, (Erişim Tarihi: 7 Aralık 2023)
- URL-3: <https://livingatlas.arcgis.com/landcoverexplorer/#mapCenter=19.228%2C52.406%2C7&mode=step&timeExtent=2017%2C2022&year=2022&downloadMode=true>, (Erişim Tarihi: 21 Şubat 2024).
- URL-4: https://developers.google.com/earth-engine/datasets/catalog/GOOGLE_DYNAMICWORLD_V1, (Erişim Tarihi: 21 Şubat 2024).

İç mekân harita yapımı için makine öğrenmesiyle nokta bulutlarının sınıflandırılması

Sena Varbil^{1*} , Alper Şen¹ 

¹Yıldız Teknik Üniversitesi, Davutpaşa Kampüsü, İnşaat Fakültesi, Harita Mühendisliği Bölümü, Esenler, İstanbul.

Öz: İç mekânlara ait 3-Boyutlu nokta bulutu sınıflandırması, iç mekân harita yapımı, iç mekân navigasyonu, bina yenileme, tesis yönetimi vb. uygulamalarda iç mekân modellerinin oluşturulmasında büyük önem taşımaktadır. Bu çalışmada, Stanford Üniversitesi tarafından üretilen S3DIS (Stanford 3D Indoor Scene) veri setinde bulunan ofis odalarına ait nokta bulutları makine öğrenmesi yöntemlerinden Rasgele Orman (RO) ve Çok Katmanlı Algılayıcı (ÇKA) ile sınıflandırılarak iç mekân haritaları oluşturulmuştur. Giriş verileri için X, Y, Z ve R, G, B öznitelik bilgileri kullanılmıştır. Sınıflar tavan, zemin, duvar, kapı, pencere, kolon, masa, sandalye, pano, dağınıklık ve kitaplık nesnelerini kapsamaktadır. Eğitim ve test verilerinde iç mekân haritalarının oluşturulması amacıyla duvar, kapı, pencere, kolon, pano ve kitaplık bir sınıf (birleştirilmiş sınıf-1); masa, sandalye ve dağınıklık bir sınıf (birleştirilmiş sınıf-2) halinde birleştirilmiştir. Eğitim verisi için bir ofis kullanılmış ve beş ayrı ofiste test edilmiştir. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. Böylece özellikle yüksek doğrulukla sınıflandırılan tavan ve birleştirilmiş sınıf-1 nesnelere sayesinde iç mekân haritaları da yüksek doğrulukla elde edilmiştir.

Anahtar Sözcükler: İç mekân, Nokta bulutu, Sınıflandırma, Makine öğrenmesi, Rasgele Orman, Çok Katmanlı Algılayıcı

Classification of indoor point clouds using machine learning for indoor mapping

Abstract: 3-Dimensional point cloud classification of interior spaces is of great importance in the creation of interior models in applications such as indoor mapping, indoor navigation, building renovation, facility management, etc. In this study, point clouds of office rooms in the S3DIS (Stanford 3D Indoor Scene) dataset produced by Stanford University were classified with Random Forest (RF) and Multilayer Perceptron (MLP) machine learning methods, and indoor maps were created. For input data, attributes X, Y, Z and R, G, B were used. The classes include ceiling, floor, wall, door, window, column, table, chair, board, clutter, and bookcase objects. To create indoor maps in the training and test data, the classes were merged as follows: wall, door, window, column, board, and bookcase were merged into one class (merged class-1), and table, chair, and clutter were merged into another class (merged class-2). An office was used for the training data and tested in five different offices. The RF method achieved an average classification accuracy of 88%, and the MLP method achieved an average accuracy of 85%. Thus, indoor maps were obtained with high accuracy, especially thanks to the ceiling and merged class-1, which were classified with high accuracy.

Keywords: Indoor, Point cloud, Classification, Machine learning, Random Forest, Multi-Layer Perceptron

* Sorumlu Yazar/Corresponding Author: Tel: +90 212 383 5344

Geliş Tarihi/Received: 14.12.2023
Kabul Tarihi/Accepted: 23.02.2024



0009-0002-4920-5085, sena.varbil@std.yildiz.edu.tr (Varbil S.)*
0000-0002-7236-6701, alpersen@yildiz.edu.tr (Şen A.)

1. Giriş

Son yıllarda lazer tarayıcıların ve dijital görüntülerin hızla gelişmesiyle birlikte, mekânsal 3-Boyutlu (3B) nokta bulutu verileri birçok alanda yaygın olarak kullanılmaya başlanmıştır (Hsieh & Ruan, 2023). İç mekân ortamlarıyla ilişkili 3B mekânsal bilgi risk ve afet yönetimi, insan hareket yollarının belirlenmesi ve tesis yönetimi gibi çeşitli uygulamalarda giderek daha fazla talep görmektedir (Gunduz vd., 2016). Dış mekâna ait nokta bulutlarının sınıflandırılmasında önemli ilerlemeler kaydedilmiştir. Ancak iç mekân sahnelerinin dar bir çevreye, çeşitli yapısal özelliklere ve kolon, duvar vb. birçok engelleme sahip olması nedeniyle sınıflandırılması hâlâ bir sorundur (Wu vd., 2020). Bu nedenle, iç mekânların doğru ve güncel durumunu yansıtan üç boyutlu modellere ve güncel mekânsal verilere olan ihtiyaç giderek artmaktadır. İç mekân modelleme, çeşitli araç ve teknolojilerle desteklenen bir süreçtir; iç mekânların fiziksel ve işlevsel özellikleri dijital olarak temsil edilir ve yönetilir. İç mekân haritaları iç mekân ölçümlerinin sonucu olarak modelleme ile temsil, birçok iç odaklı uygulamanın temelini oluşturur (Deng vd., 2022). İç mekân ortamlarının 3B modelleri, yeniden tasarımdan izleme ve simülasyona kadar bir dizi farklı uygulama alanında kullanılabilirler için giderek daha fazla önem kazanmaktadır. Görüntülerden veya nokta bulutlarından otomatik olarak 3B iç mekânların yeniden oluşturulması süreci daha kolay, hızlı ve ekonomik hale getirmektedir (Díaz-Vilariño vd., 2015). Nokta bulutu elde edildikten sonra, genellikle içerdiği yararlı bilgilerin anlaşılması için sınıflandırılması gereklidir. Bu nedenle nokta bulutu bölütleme teknolojisi birçok uygulama için büyük önem taşır (Hsieh & Ruan, 2023). Nokta bulutu semantik bölütlemesi, nokta kümesindeki her noktayı sınıflandırmayı hedefler. Semantik bölütleme otonom navigasyon, sanal gerçeklik, robot nesne etiketleme ve yüksek kaliteli iç mekân haritalama gibi birçok gerçek dünya uygulamasına büyük ölçüde fayda sağlar (Lin vd., 2021). Nokta bulutu için geleneksel bölütleme yöntemleri birçok araştırmacının çalışmalarıyla sürekli olarak geliştirilmiştir. Bununla birlikte, geleneksel nokta bulutu bölütleme yöntemleri, manuel olarak etiketleme yoluyla tasarımcıların deneysel bilgiye sahip olmasını gerektirmektedir. Nokta bulutu bölütlemesinde kullanılması gereken bir dizi eşik değeri bulunur ve bu yöntemler genellikle karmaşık olduğundan, yalnızca belirli görevler için uygunken genel olarak performansları zayıf kalmaktadır (Zhao vd., 2020).

İç mekân konumlandırma için birçok teknik mevcut olsa da iç mekân konum bilgisini ölçümlerden çıkarabilen sınırlı sayıda algoritma ve yöntem bulunmaktadır. Üç boyutlu mekânsal veri edinimi, şehir ve bina modelleme alanında bilimsel ve teknolojik olarak hızla ilerlemektedir. Bu ilerlemeler, iç mekân modelleme ve harita yapımı için daha gelişmiş donanım, yazılım, standartlar, teknikler ve uygulamaların ortaya çıkmasını sağlamaktadır. Sensörler, iç mekân bilgisi ediniminde anahtar bir rol oynamaktadır (Gunduz vd., 2016). İç mekân nokta bulutu veri toplama sistemleri, fiziksel yapılarına göre el tipi, sırt çantası ve el arabası gibi sınıflara ayrılabilir. Araba konfigürasyonu, geniş bir sensör seçimi ve ağırlık esnekliği sunarak daha güçlü sensörlere erişim sağlar. Bu durum, daha güçlü sensörlerle daha yoğun nokta bulutu verisi sağlayabilir. Ancak, daha güçlü sensörlerin kullanımı araç maliyetini artırabilir ve manevra kabiliyetini azaltabilir. Özellikle dar alanlarda veya sınırlı alanlarda (merdivenler veya dar koridorlar gibi) fiziksel kısıtlamalarla karşılaşılabilir. Öte yandan, elde taşınabilir cihazlar daha fazla manevra kabiliyetine sahiptir ve satın alırken daha fazla esneklik sağlayabilirler. Ancak, bu cihazların sınırlı ağırlık taşıma kapasitesi ve pil ömrü, harita yapımı sensörünün özelliklerini ve tamamlayıcı sensörlerin kullanımını kısıtlayabilir. Bu durum, belirli özelliklerin entegrasyonunda ve ek sensörlerin kullanımında bazı sınırlamalara yol açabilir. Veri işleme ve sensör senkronizasyonunda temel unsur, genellikle LiDAR veya RGB-D kamerası gibi donanımları içinde barındıran harita yapımı sensörüdür (Otero vd., 2020). Böylece 3B tarayıcılar büyük miktarda veriyi yakalayarak yapay zeka destekli makinelerin dünyayı daha doğru algılamasını ve tanınmasını sağlamaktadır (Shan vd., 2023).

Kartografik harita yapımının başlıca odak noktasının mekânsal bilginin etkin bir şekilde aktarımını geliştirmek olduğu düşünüldüğünde, nokta bulutları ve örgülü (meshed) modeller genellikle harita olarak kabul edilmezken, mimari CAD çizimleri ve Yapı Bilgi Modellemesi (Building Information Modeling, BIM) ise ilkel haritalar olarak düşünülebilir. İç mekân

ortamlara ait kartografik özellikler taşıyan haritalarının yapımı, iç mekânları modelleyen diğer disiplinlerle hem örtüşmekte hem de onlardan ayrılmakta ve iç mekân temsiline nispeten keşfedilmemiş bir alanı temsil etmektedir. Bu bağlamda, nokta bulutlarının bölütlenmesi sonucunda elde edilen nesne sınıfları kullanılarak kartografik haritaların yapımı önemli bir araştırma konusudur (Chen & Clarke, 2020). İç mekânlarda insanlar için haritaların oluşturulması, özellikle büyük ve karmaşık yapılar için oldukça önemlidir. Bu tür haritalar, ziyaretçilere veya çalışanlara mekân içindeki konumlarını belirleme ve istedikleri hedefe yönlendirme konusunda yardımcı olabilir. İç mekânın güncel durumunu yansıtan nokta bulutlarının yüksek doğruluklu nesne sınıflarını sağlayacak biçimde bölütlenmesi ile iç mekâna ait haritalarının oluşturulması ve bu haritalardan iç mekân navigasyon ağ modellerinin otomatik olarak üretimi iç mekân navigasyonu sistemlerinin önemli bileşenleri arasında yer alır (Bilgili vd., 2022).


Armeni vd. (2016) tarafından büyük ölçekli ve renkli S3DIS (Stanford 3D Indoor Scene) iç mekân veri seti üretilmiş ve hiyerarşik bir yaklaşım kullanılarak tüm bir binanın 3B nokta bulutunun anlamsal ayrıştırılması için bir yöntem önerilmiştir. Çalışmada önce noktalar arasındaki boşluk örüntülerini temel alan bir algoritma ile yatay ve düşey eksenler kullanılarak nokta bulutu yatay ve düşey alanlara bölütlenmiştir. Aşırı bölütlenmiş alanlar, topolojik düğüm noktaları arasındaki ilişkiler kullanılarak birleştirilmiştir. Böylece ana ayırıcı niteliğinde olan binaya ait duvar noktaları sınıflandırılmıştır. Diğer nesnelere, belli bir koordinat sistemine getirilen bölütlenmiş alanlarda 3B kutular gezdirilerek sınıflandırılmıştır. Bu yöntem ile tahmin edilen sınıf etiketleri, uzmanlarca manuel olarak sınıflandırılarak üretilen referans (ground truth) etiketleri ile karşılaştırıldığında tavan ve zemin sınıfı için sırasıyla %71.61 ve %88.70 doğruluk; duvar, kolon ve pencere gibi temel bina elemanlarına ait sınıflar için ise %67.38 genel doğruluk elde edilmiştir. Poux vd. (2020) tarafından, 3B iç mekân nokta bulutlarını etkili bir şekilde kümelenebilirliği için denetimsiz bir bölge büyüme bölütlemesi yaklaşımı sunulmuştur, optimal parametreleri tanımlamak için öğrenme tabanlı sezgisel bir süreç önerilmiş ve S3DIS veri seti üzerinde test edilmiştir. Nesne tabanlı sınıflandırma için ortalama %88.10 F1 doğruluk elde edilmiştir. Chen vd. (2021) tarafından, dikkat modülü ile halka gruplama sinir ağı adlı yeni bir ağ mimarisi önerilmiştir. Önerilen ağ mimarisinin performansı S3DIS, ScanNet ve NYU-V2 gibi veri kümeleri üzerinde değerlendirilmiş ve S3DIS veri setinde en iyi genel doğruluk ve ortalama kesişim (mean intersection-over-union, mIoU) değerleri elde edilmiştir. Çalışma sonucunda genel doğruluk %87.05 olarak elde edilmiştir. Su vd. (2022) tarafından, çok ölçekli seyrek evrişime dayalı çok ölçekli bir öznetelik birleştirme modülü ve kanal dikkat mekanizmasına dayalı bir kanal öznetelik filtreleme modülü önerilmiştir. S3DIS veri seti üzerinde yapılan çalışmada önerilen yöntem ile %74.90 ile en yüksek doğruluk metriği elde edilmiştir. Hsieh ve Ruan (2023) tarafından, iç mekân nokta bulutlarında sütun, giriş, duvar, zemin ve tavan noktalarını otomatik olarak bölütlemek için dinamik grafik evrişimli sinir ağı kullanılmıştır. S3DIS iç mekân veri setinin kullanıldığı çalışmada %86.90 doğruluk elde edilmiştir.

Bu çalışmada, Stanford Üniversitesi tarafından üretilen S3DIS veri setinde bulunan bazı ofis odalarına ait nokta bulutlarının makine öğrenmesi yöntemlerinden Rasgele Orman (RO) ve Çok Katmanlı Algılayıcı (ÇKA) ile sınıflandırılarak iç mekân haritalarının oluşturulması amaçlanmaktadır. Veri setindeki her sınıf için kesinlik, duyarlılık, F1 skor ve doğruluk değerleri hesaplanmıştır. Uygulamadaki tüm işlemler ve sınıflandırma aşamaları Python programlama diline ait Scikit-learn kütüphanesi kullanılarak, görselleştirmeler ise Cloud Compare ve ArcGIS Pro yazılımları ile yapılmıştır. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. Böylece özellikle yüksek doğrulukla sınıflandırılan tavan ve birleştirilmiş sınıf-1 kesişimleri sayesinde iç mekân haritaları da yüksek doğrulukla elde edilmiştir.

2. Metodoloji

Bu çalışmaya ait iş akışı, verinin düzenlenmesi, sınıfların birleştirilmesi, normalizasyon, RO ve ÇKA ağ modellerinin oluşturulması, model parametrelerinin belirlenmesi, bir ofis için eğitim (%70) ve test (%30) setlerinin belirlenmesi ile model

eğitiminin gerçekleştirilmesi, beş farklı ofise ait nokta bulutu sınıflandırmasının doğruluk metrikleri ile değerlendirilmesi adımlarından oluşmaktadır. Şekil 1’de çalışmaya ait akış diyagramı verilmiştir.



Şekil 1: İç mekân nokta bulutu verisinin makine öğrenmesi yöntemleriyle sınıflandırılması iş akış şeması

2.1 Min-Max Normalizasyonu

Min-max normalizasyon tekniği, değişkenlere ait ortalama ve varyans değerleri birbirinden anlamlı derecede farklı olduğu durumlarda kullanılır ve orijinal veri seti üzerinde doğrusal bir dönüşüm gerçekleştirir (Kiran & Vasumathi, 2020). Bu çalışmada, X, Y, Z, R, G, B değerleri min - max normalizasyonu kullanılarak normalize edilmiştir. Min-max normalizasyonu Eşitlik 1’de gösterilmiştir.

$$X'_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Burada X'_i normalizasyon değerini, X_i öznelilik değerini, X_{min} en küçük öznelilik değerini, X_{max} en büyük öznelilik değerini ifade etmektedir.

2.2 Kullanılan Makine Öğrenmesi Yöntemleri

2.2.1 Rastgele Orman (RO) Yöntemi

Rastgele Orman (RO), ilk olarak Breiman (2001) tarafından bulunmuştur. Rastgele Orman, birçok karar ağacını belirli bir kombinasyon kullanarak bir araya getiren topluluk öğrenme yöntemidir. (Sun vd., 2024). Her ağaç, etiketlenmemiş bir örneğin sınıfını belirlemek için temel sınıflandırıcı işlevini yerine getirir. Bu süreçte, her sınıflandırıcı, tahmini sınıf etiketi için oy kullanır ve ardından en yüksek oyu alan sınıf etiketi, örneğin sınıflandırılmasında kullanılır (Fawagreh vd., 2014).

Yeni bir x örneğinde tahmin yapmak için; B rastgele orman ağaç sayısı, $C_b(x)$ b 'inci rastgele orman ağacının tahmini olduğunda aşağıdaki eşitlik elde edilir (Hastie vd., 2009):

$$C_{ro}^B(x) = \text{çoğunluk oyu}\{C_b(x)\}_1^B \quad (2)$$

2.2.2 Çok Katmanlı Algılayıcı (ÇKA) Yöntemi

Çok Katmanlı Algılayıcı (ÇKA), bilginin giriş katmanından çıkış katmanına, gizli katmanlardan geçerek tek yönlü olarak aktığı, katmanlı ileri beslemeli geri yayımlı bir sinir ağıdır (Bishop, 1995) ÇKA'nın giriş katmanında, veriler alınır ve ardından toplama fonksiyonu kullanılarak bir aktivasyon fonksiyonuna iletilir. Her katmanda bu aktivasyon fonksiyonları kullanılarak hesaplamalar yapılır ve çıkış bir sonraki katmana iletilir. Bu işlem, çıkış katmanına ulaşana kadar tekrarlanır. Çıkış katmanında hesaplanan hatalar geri yayılım algoritmaları ile ağırlıkların güncellenmesinde kullanılır ya da nihai karar verilir. ÇKA modelinin performansı eğitim verilerinin sayısına, değişken seçimine, gizli katman ve düğüm sayılarına, öğrenme ve momentum katsayıları ve iterasyon sayısı gibi eğitim parametrelerine bağlıdır. Öğrenme ve momentum

katsayıları, öğrenme sürecinin hızını ve etkinliğini kontrol eder (Taud & Mas, 2018). Çıktı hesaplama Eşitlik 2’de gösterilmiştir (Sen & Gumus, 2023).

$$I_j = \sum_i w_{ij} O_i + \theta_j \quad (3)$$

Burada, I_j j düğümünün çıktısını; w_{ij} i ve j düğümü arasındaki ağırlığı, O_i bir önceki katmandan gelen i düğümünün çıktısını ve θ_j j düğümünün eşik değerini ifade eder.

2.2.3 Model Değerlendirme Ölçütleri

Makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan çeşitli metrikler bulunmaktadır. Bu çalışmada, model değerlendirmesi için eşitlik (4), (5), (6) ve (7)’de verilen doğruluk, duyarlılık, kesinlik ve F1 skoru metrikleri kullanılmıştır. Bu metrikler, modellerin başarılarını değerlendirmek ve karşılaştırmak için kullanılmaktadırlar.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (5)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{F1 Skoru} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$


Burada; doğru pozitif (DP) modelin doğru bir şekilde pozitif bir durumu tanımladığı durumu, doğru negatif (DN) doğru negatif bir durumu tanımladığı durumu, yanlış pozitif (YP) aslında negatif olan bir durumu pozitif olarak tanımladığı durumu, yanlış negatif (YN) ise modelin aslında pozitif olan bir durumu negatif olarak tanımladığı durumu temsil etmektedir.

3. Çalışma Alanı ve Veriler

Bu çalışmada S3DIS (Stanford 3D Indoor Scene Dataset) veri seti kullanılmıştır. Veri seti, her tarama konumunda, 360° dönüş sırasında farklı açılarda üç adet yapılandırılmış ışık sensörünü birleştirerek 18 RGB ve derinlik görüntüsü yakalayabilen Matterport Kamera ile oluşturulmuştur. Veri kümesi, her taranan alan için renkli nokta bulutları içermektedir. Çoğunlukla eğitim ve ofis kullanımına yönelik üç farklı binadan taranan altı büyük ölçekli iç mekân alanından toplanmıştır. Veri setinde toplam 70 496 düzenli RGB ve 1413 eş dikdörtgen RGB görüntüsü bulunur. Ayrıca veri kümesindeki tüm görüntüler 1080x1080 çözünürlükte depolanmıştır. Tüm veri setinde yapısal elemanlar (tavan, zemin, duvar, giriş, sütun, pencere ve kapı) ve yaygın olarak bulunan eşyalar ve mobilyalar (masa, sandalye, kanepeler, kitaplık ve tahta) olmak üzere 12 sınıf bulunmaktadır (Armeni vd., 2016). Veri X, Y, Z, R, G, B ve uzmanlarca manuel olarak sınıflandırılarak üretilen referans (ground truth) etiketinden oluşmaktadır. Bu çalışmada makine öğrenme yöntemi ile sınıflandırmak üzere S3DIS veri setinde ofis kullanımına yönelik hazırlanmış veri setleri eğitim ve test verisi olarak ayrılmıştır. Ofis 1 verisi, %70’i eğitim %30’u test olarak ayrılmıştır. Bu oranların öğrenme performansı için uygun olduğu deneysel olarak gözlemlenmiştir. Buna ek olarak, beş ayrı ofis verisi üzerinde elde edilen test sonuçlarına göre modelin eğitimde aşırı uyum (overfitting) göstermediği de anlaşılmaktadır.

4. Uygulama ve Bulgular

Çalışma alanında tavan, zemin, duvar, kapı, pencere, kolon, masa, sandalye, pano, dağınıklık ve kitaplık olarak toplam 11 sınıf bulunmaktadır. Eğitim ve test verilerinde iç mekân haritalarının oluşturulması amacıyla duvar, kapı, pencere, kolon, pano ve kitaplık bir sınıf (birleştirilmiş sınıf-1); masa, sandalye ve dağınıklık bir sınıf (birleştirilmiş sınıf-2) olacak şekilde sınıflar Python programlama dilinde kod yazılarak birleştirilmiştir. Tavan için 0, zemin için 1, birleştirilmiş sınıf-1 için 2, birleştirilmiş sınıf-2 için ise 3 etiketi verilmiştir. Nokta bulutlarına ait sınıflar işaret anahtarındaki (lejanttaki) renklerle Şekil 2’de gösterilmiştir.



Şekil 2: Nokta bulutlarına ait 11 adet sınıf: (a) Ofis 1, (b) Ofis 2, (c) Ofis 3, (d) Ofis 4, (e) Ofis 5, (f) Ofis 6

Sonrasında özneliklere (X, Y, Z, R, G, B) min-max normalizasyonu yapılmıştır. Daha sonra RO ve ÇKA yöntemine göre model parametreleri Python dilinde döngüler yardımıyla (parametre değişkenlerini içeren) liste yapısı kullanılarak deneysel olarak sınanmıştır ve en iyi parametreler seçilmiştir. Ofis 2 için sınıflandırma sonuçları Tablo 1’de, Ofis 3 için sınıflandırma sonuçları Tablo 2’de, Ofis 4 için sınıflandırma sonuçları Tablo 3’te, Ofis 5 için sınıflandırma sonuçları Tablo 4’te ve Ofis 6 için sınıflandırma sonuçları Tablo 5’te gösterilmiştir.

Tablo 1: Ofis 2 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.98	0.96	0.99	0.99	0.99	0.97
1	1.00	1.00	0.58	0.49	0.73	0.66
2	0.89	0.90	0.89	0.83	0.89	0.86
3	0.42	0.39	0.60	0.72	0.49	0.50

Doğruluk: 0.83 (RO), 0.80 (ÇKA)

Ofis 2 için RO yöntemiyle %83, ÇKA yöntemi ile %80 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %97; zemin (1 etiketi) RO yöntemiyle %73, ÇKA yöntemiyle %66; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %89, ÇKA yöntemiyle %86; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %49, ÇKA yöntemiyle %50 doğruluğu elde edilmiştir. Tavan, zemin ve birleştirilmiş sınıf-1 için RO yöntemi; birleştirilmiş sınıf-2 için ise ÇKA yönteminin daha iyi sonuç verdiği görülmüştür.

Tablo 2: Ofis 3 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.99	0.98	0.99	0.93	0.99	0.96
1	0.97	0.98	1.00	1.00	0.99	0.99
2	0.88	0.86	0.96	0.89	0.92	0.88
3	0.87	0.69	0.64	0.63	0.74	0.66

Doğruluk: 0.91 (RO), 0.87 (ÇKA)

Ofis 3 için RO yöntemiyle %91, ÇKA yöntemi ile %87 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %96; zemin (1 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %99; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %92, ÇKA yöntemiyle %88; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %74, ÇKA yöntemiyle %66 F1 doğruluğu elde edilmiştir. Tavan, birleştirilmiş sınıf-1 ve birleştirilmiş sınıf-2 için RO yöntemi daha iyi sonuç vermiş; zemin için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Tablo 3: Ofis 4 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.98	0.96	0.98	0.99	0.98	0.97
1	0.97	0.98	0.99	0.99	0.98	0.98
2	0.95	0.95	0.87	0.82	0.91	0.88
3	0.54	0.46	0.77	0.77	0.63	0.58

Doğruluk: 0.90 (RO), 0.87 (ÇKA)

Ofis 4 için RO yöntemiyle %90, ÇKA yöntemi ile %87 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %97; zemin (1 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %98; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %91, ÇKA yöntemiyle %88; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %63, ÇKA yöntemiyle %58 F1 doğruluğu elde edilmiştir. Tavan, birleştirilmiş sınıf-1 ve birleştirilmiş sınıf-2 için RO yöntemi daha iyi sonuç vermiş; zemin için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Tablo 4: Ofis 5 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.97	0.95	0.98	0.94	0.97	0.95
1	0.96	0.96	0.99	1.00	0.97	0.98
2	0.95	0.94	0.88	0.85	0.91	0.90
3	0.52	0.49	0.70	0.74	0.59	0.59

Doğruluk: 0.90 (RO), 0.88 (ÇKA)

Ofis 5 için RO yöntemiyle %90, ÇKA yöntemi ile %88 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %95; zemin (1 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %98; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %91, ÇKA yöntemiyle %90; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %59, ÇKA yöntemiyle %59 F1 doğruluğu elde edilmiştir. Tavan ve birleştirilmiş sınıf-1 için RO yöntemi daha iyi sonuç vermiş, zemin için ÇKA yöntemi, birleştirilmiş sınıf-2 için ise iki yöntemin aynı sonucu verdiği görülmüştür.


Tablo 5: Ofis 6 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.97	0.96	0.98	1.00	0.98	0.98
1	0.99	0.99	0.94	0.92	0.97	0.96
2	0.91	0.92	0.86	0.82	0.88	0.86
3	0.55	0.51	0.67	0.73	0.61	0.66


Doğruluk: 0.87 (RO), 0.85 (ÇKA)

Ofis 6 için RO yöntemiyle %87, ÇKA yöntemi ile %85 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %98; zemin (1 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %96; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %88, ÇKA yöntemiyle %86; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %61, ÇKA yöntemiyle %66 F1 doğruluğu elde edilmiştir. Zemin ve birleştirilmiş sınıf-1 için RO yöntemi; birleştirilmiş sınıf-2 için ÇKA yöntemi; tavan için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Yapılan uygulama sonucunda en yüksek doğruluk RO yöntemi için %91 ile Ofis 3 verisi; ÇKA yöntemi için ise %88 ile Ofis 5 verisi olmuştur. Ofis 3 ve Ofis 5 verisi ile ilgili referans sınıfları, tahmin edilen sınıflar ve DP, DN, YP ve YN sınıfları işaret anahtarındaki (lejanttaki) renklerle Şekil 3 ve Şekil 4'te gösterilmiştir. Şekil 3 ve Şekil 4'te referans sınıflarının (Şekil 3a) tahmin edilen sınıflar (Şekil 3b) ile karşılaştırılması yoluyla doğru ve yanlış tahminlerin (Şekil-3c) incelenmesi sonucunda, tavan, zemin, duvar, kapı, pencere, kolon ve sandalye gibi sınıflarının yeterince doğru sınıflandırıldığı, ancak masa, pano, kitaplık ve dağınıklık gibi sınıflarda hatalı tahminlerin olduğu görülmektedir.



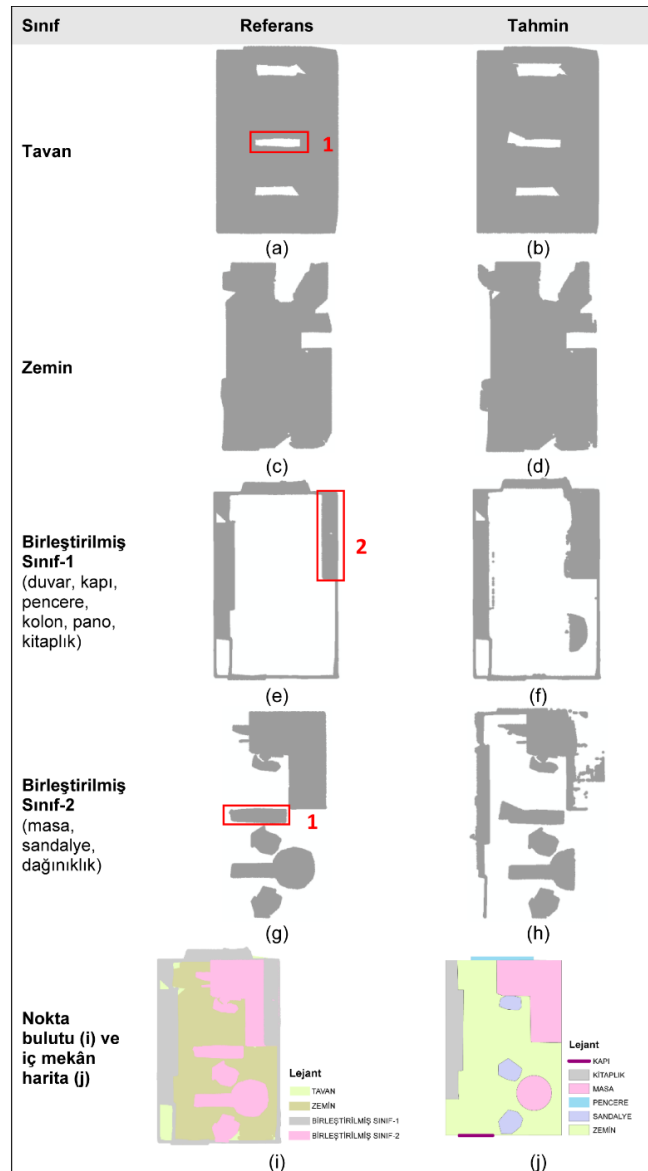
Şekil 3: Ofis 3 verisi üzerindeki RO'ya göre doğruluk sonuçları: (a) Referans sınıflar, (b) tahmin edilen sınıflar, (c) doğru sınıflandırma (DP ve DN) ve yanlış sınıflandırma (YP ve YN)



Şekil 4: Ofis 5 verisi üzerindeki ÇKA'ya göre doğruluk sonuçları: (a) Referans sınıflar, (b) tahmin edilen sınıflar, (c) doğru sınıflandırma (DP ve DN) ve yanlış sınıflandırma (YP ve YN)

Sınıflandırılan nokta bulutunun harita yapımına uygunluğu ArcGIS Pro yazılımı kullanılarak incelenmiştir. Noktaların dış sınırlarına uyan çokgenler Minimum Sınırlayıcı Geometri (Minimum Bounding Geometry) aracında bulunan dışbükey gövde (convex hull) ve daire gibi geometriler kullanılarak oluşturulmuş ve manuel olarak köşe noktaları düzeltilmiştir. RO yöntemi kullanılarak sınıflandırılan Ofis 5 nokta bulutuna ait referans veri sınıfları tavan, zemin, birleştirilmiş sınıf-1, birleştirilmiş

sınıf-2 ve tüm nokta bulutu Şekil 5 (a, c, e, g, i)'de verilmiştir. Tahmin edilen veri sınıflarına ait tavan, zemin, birleştirilmiş sınıf-1, birleştirilmiş sınıf-2 ve sonuç harita ise Şekil 5 (b, d, f, h, j)'de verilmiştir. Tavan noktalarında bulunan boşluğun sebebi dağınıklık sınıfına ait aydınlatma nesnesidir (Şekil 5'te 1 numaralı kırmızı çerçeve). Sonuçlar incelendiğinde referans (Şekil 5a ve 5c) ve sınıflandırılan (Şekil 5b ve Şekil 5d) tavan ve zemin nokta bulutlarının birbirine çok yakın olduğu görülmektedir. Zemin üzerinde yer alan nesnelere nedeniyle nokta verisinin zeminin tümünü kapsamadığı ve zeminde çeşitli boşluklara sahip olduğu görülmektedir. Bu nedenle zemin noktaları harita yapımı için uygun bir nesne sınıfı değildir. Şekil 5j'de gösterilen harita incelendiğinde, zemin (aynı zamanda iç duvar), kapı, pencere, masa, sehpa ve sandalyelerin çizilebildiği görülmektedir. Birleştirilmiş sınıf-1'de yer alan iki kitaplıktan biri çizilebilecek kadar sınıflandırılabilmiş, ancak Şekil 5e'de 2 numaralı kırmızı çerçeve içinde yer alan diğer kitaplık yeterince sınıflandırılmamıştır. Bunun nedeni, kitaplığın masa üzerinde yer alması ile karmaşık bir yapı göstermesidir. Bu yüzden bu nesne haritada çizilememiştir. Ayrıca masa sınıfındaki sehpa nesnesine ait nokta bulutunun yaklaşık yarısı, birleştirilmiş sınıf-2 (Şekil 5h) yerine yanlışlıkla birleştirilmiş sınıf-1'de sınıflandırılmıştır (Şekil 5f). Ancak yine de daire geometrisi ile çizilerek haritada gösterilebilmiştir (Şekil 5j). Sonuç olarak sınıflandırılan noktalar incelendiğinde hatalı sınıflandırma genellikle kitaplık ve masa nesnelerinde gerçekleşmiş, bu nesne sınıflarının çiziminde birtakım güçlükler yaşanmıştır.



Şekil 5: Ofis 5 için RO ile sınıflandırma sonucunda harita yapımı: (a, c, e, g, i) Referans nokta bulutu, (b, d, f, h) sınıflandırılan nokta bulutu ve (j) sonuç harita.

5. Sonuç ve Öneriler

Eğitim verisi için bir ofis kullanılmış ve beş ayrı ofiste test edilmiştir. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. İç mekân nokta bulutu sınıflandırmasında RO yöntemi ÇKA yöntemine genelde üstünlük sağlamıştır. Her iki yöntem tavan, zemin ve birleştirilmiş sınıf-1 (duvar, kapı, pencere, kolon, pano ve kitaplık) sınıflarını etkili bir şekilde tahmin etmiştir. Ancak, birleştirilmiş sınıf-2'de bulunan masa, sandalye ve dağınıklık nesnelere tahmin etmekte her iki yöntem de yeterli olamamıştır. Yine de birleştirilmiş sınıf-2'de bulunan nesnelere için harita üzerinde çizim yapmaya yeterli olacak kadar doğru tahmin çoğunlukla yapılabilmektedir. İç mekân harita yapımı ve yaya navigasyonu için gerekli tüm sınıflar (tavan, zemin ve birleştirilmiş sınıf-1) yüksek doğrulukla sınıflandırılmıştır. Bu çalışma, makine öğrenimi kullanılarak iç mekân nokta bulutlarının sınıflandırma performansını harita yapımı için değerlendirmiştir. Böylece, RO ve ÇKA yöntemlerinin iç mekân nokta bulutlarının sınıflandırılmasında literatürde gösterilen yöntemlere göre yeterli doğruluk sağladığı (Armeni vd., 2017; Chen vd., 2021; Hsieh & Ruan, 2023; Poux vd., 2020; Su vd., 2022) ve tahmin edilen nesne sınıflarının iç mekân harita yapımında kullanılabildiği tespit edilmiştir. Gelecek çalışmalarda iç mekân nokta bulutlarının sınıflandırması için farklı makine öğrenimi yöntemlerinin performansı sınanabilir. Bu çalışmada iç mekân haritası yarı otomatik olarak yapılmış olup ileride Python gibi programlama dillerinin geometri kütüphaneleri kullanılarak tam otomatik olarak çizilmesi yoluyla iç mekân harita yapımının değerlendirilmesi araştırılabilir.

Yazar Katkısı

Sena Varbil: Literatür taraması, Veri işleme, Sınıflandırma uygulaması, Yazım. **Alper Şen:** Fikir, Literatür taraması, Denetleme, Veri toplama ve işleme, Analiz.

Çıkar Çatışması Beyanı

Yazarlar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Armeni, I., Sener, O., Zamir, A. R., Jiang, H., Brilakis, I., Fischer, M., & Savarese, S. (2016). 3d semantic parsing of large-scale indoor spaces. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1534-1543.
- Bilgili, A., Şen, A., & Başaraner, M. (2022). İç mekân navigasyonu ağ modelleri: Karşılaştırmalı bir inceleme. *Jeodezi ve Jeoinformasyon Dergisi*, 9(2), 108-126.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Chen, J., & Clarke, K. C. (2020). Indoor cartography. *Cartography and Geographic Information Science*, 47(2), 95-109.
- Chen, X. T., Li, Y., Fan, J. H., & Wang, R. (2021). RGAM: A novel network architecture for 3D point cloud semantic segmentation in indoor scenes. *Information Sciences*, 571, 87-103.
- Deng, Y., Ai, H., Deng, Z., Gao, W., & Shang, J. (2022). An overview of indoor positioning and mapping technology standards. *Standards*, 2(2), 157-183.
- Díaz-Vilariño, L., Khoshelham, K., Martínez-Sánchez, J., & Arias, P. (2015). 3D modeling of building indoor spaces and closed doors from imagery and point clouds. *Sensors*, 15(2), 3491-3512.
- Fawagreh, K., Gaber, M. M., & Elyan, E. (2014). Random forests: from early developments to recent advancements. *Systems Science & Control Engineering: An Open Access Journal*, 2(1), 602-609.
- Gunduz, M., Isikdag, U., & Basaraner, M. (2016). A review of recent research in indoor modelling & mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 289-294.

- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction*. New York: Springer.
- Hsieh, C. S., & Ruan, X. J. (2023). Automated Semantic Segmentation of Indoor Point Clouds from Close-Range Images with Three-Dimensional Deep Learning. *Buildings*, 13(2), 468.
- Kiran, A., & Vasumathi, D. (2020). Data mining: min-max normalization based data perturbation technique for privacy preservation. *Proceedings of the Third International Conference on Computational Intelligence and Informatics: ICCII 2018*, 723-734, Singapore: Springer Singapore.
- Lin, H., Wu, S., Chen, Y., Li, W., Luo, Z., Guo, Y., Wang, C., & Li, J. (2021). Semantic segmentation of 3D indoor LiDAR point clouds through feature pyramid architecture search. *ISPRS Journal of Photogrammetry and Remote Sensing*, 177, 279-290.
- Otero, R., Lagüela, S., Garrido, I., & Arias, P. (2020). Mobile indoor mapping technologies: A review. *Automation in Construction*, 120, 103399.
- Poux, F., Mattes, C., & Kobbelt, L. (2020). Unsupervised segmentation of indoor 3D point cloud: Application to object-based classification. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 44, 111-118.
- Sen, A., & Gumus, K. (2023). Comparison of Different Parameters of Feedforward Backpropagation Neural Networks in DEM Height Estimation for Different Terrain Types and Point Distributions. *Systems*, 11(5), 261.
- Shan, D., Zhang, Y., Wang, X., Luo, W., Meng, X., Liu, Y., & Gao, X. (2023). An Efficient Point Cloud Semantic Segmentation Method Based on Bilateral Enhancement and Random Sampling. *Electronics*, 12(24), 4927.
- Su, Y., Jiang, L., & Cao, J. (2022). Point Cloud Semantic Segmentation using Multi Scale Sparse Convolution Neural Network. *arXiv:2205.01550*.
- Sun, Z., Wang, G., Li, P., Wang, H., Zhang, M., & Liang, X. (2024). An improved random forest based on the classification accuracy and correlation measurement of decision trees. *Expert Systems with Applications*, 237, 121549.
- Taud, H., & Mas, J. F. (2018). Multilayer perceptron (MLP). *Geomatic approaches for modeling land change scenarios*, 451-455.
- Wu, H., Yang, H., Huang, S., Zeng, D., Liu, C., Zhang, H., Guo, C., & Chen, L. (2020). Classification of point clouds for indoor components using few labeled samples. *Remote Sensing*, 12(14), 2181.
- Zhao, J., Zhang, X., & Wang, Y. (2020). Indoor 3D point clouds semantic segmentation bases on modified pointnet network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 369-373.

Examining the accuracy of DEM of difference and 3D point cloud comparison methods: Open pit mine case study

Nilufer Ozdas¹ , Mehmet Guven Kocak^{2*} , Serkan Karakis² 

¹İzmir Kâtip Çelebi University, Institute of Science, Geomatics Engineering, Çiğli, İzmir, Türkiye.

²İzmir Kâtip Çelebi University, Faculty of Engineering and Architecture, Department of Geomatics Engineering, Çiğli, İzmir, Türkiye.

Abstract: With the widespread use of unmanned aerial vehicles (UAV), high-accuracy photogrammetric mapping studies can be carried out over small areas with cost-effective simple systems. By comparing images obtained at different epochs, 3 Dimensional (3D) change detection studies can be easily performed. Digital surface models (DSM) are obtained from the point cloud (PC) with the processing software, their differences are taken, and temporal changes can thus be modeled. This method is known as DEM (DSM) of Difference (DoD) in practice and has low computational cost. Recently, with the availability and accessibility of powerful computers capable of processing increasing amounts of data, 3D change detection studies can be performed directly with raw PCs without converting them to DSM. Methodologically, DoD and PC-based analysis strategies have different evaluation stages and outputs. With DoD, only changes in the vertical direction can be revealed, while PC comparison methods can produce the 3D change vector. In this study, the well-established DoD method and Multiscale Model-to-Model Cloud Comparison (M3C2), one of the 3D PC comparison methods, were compared. The accuracy of the methods was tested at an active open pit mine site where intensive excavation works have been undertaken. Standard deviation values were found below 11 cm with M3C2 distance and DoD differences obtained from UAV images having average ground sampling distances (GSD) of 5.8-6.9 cm. Only about 1% of the differences were categorized as outliers.

Keywords: 3D point cloud, Digital surface modeling, DEM of difference, M3C2, Accuracy

Fark SYM ve 3B nokta bulutu karşılaştırma yöntemlerinin doğruluklarının incelenmesi: Açık maden ocağı örneği

Öz: İnsansız hava araçlarının (İHA) yaygınlaşmasıyla birlikte düşük maliyetli basit sistemlerle küçük alanlar üzerinde yüksek doğruluklu fotogrametrik haritalama çalışmaları yapılabilmektedir. Farklı zamanlarda elde edilen görüntüler karşılaştırılarak 3 Boyutlu (3B) değişim tespit çalışmaları da kolaylıkla gerçekleştirilebilmektedir. Fotogrametrik değerlendirme yazılımları ile elde edilen nokta bulutundan sayısal yüzey modelleri (SYM) elde edilir, farkları alınır ve zamansal değişimler modellenenir. Bu yöntem pratikte Fark SYM yöntemi olarak bilinir ve düşük hesaplama maliyetine sahiptir. Son zamanlarda, büyük veri işleyebilen güçlü bilgisayarların gelişmesi ve bunlara erişimin düşük maliyetlerle mümkün olması neticesinde 3B değişim tespit çalışmaları ham nokta bulutundan SYM elde edilmeksizin doğrudan noktaların kendisiyle yapılabilmektedir. Metodolojik olarak, Fark SYM ve nokta bulutu tabanlı analiz stratejilerinin farklı değerlendirme aşamaları ve çıktıları vardır. Fark SYM ile sadece düşey yöndeki değişimler ortaya çıkarılabilirken, ham nokta bulutu karşılaştırma yöntemleri 3B değişim vektörünü hesaplayabilmektedir. Bu çalışmada, pratikte sıklıkla kullanılan Fark SYM yöntemi ile 3B nokta bulutu karşılaştırma yöntemlerinden biri olan M3C2 karşılaştırılmıştır. Yöntemlerin doğruluğu, yoğun kazı çalışmalarının yapıldığı aktif bir açık ocak maden sahasında test edilmiştir. Ortalama yer örnekleme aralığı 5.8-6.9 cm olan İHA görüntülerinden elde edilen M3C2 uzunluk ve DoD farklarıyla 11 cm'den düşük standart sapma değerleri bulunmuştur. Farkların sadece %1 civarındaki kesimi uyumsuzuz olarak ortaya çıkmıştır.

Anahtar Sözcükler: 3B nokta bulutu, Sayısal yüzey modeli, Fark SYM, M3C2, Doğruluk

* Sorumlu Yazar/Corresponding Author: Tel: +90 232 329 3535 / 3775

Geliş Tarihi/Received: 15.01.2024

Kabul Tarihi/Accepted: 28.02.2024



0009-0007-3929-6813, niluferozdass@gmail.com (Ozdas N.)
0000-0002-7992-5860, mehmetguven.kocak@ikcu.edu.tr (Kocak M.G.)*
0000-0002-5765-7666, serkan.karakis@ikcu.edu.tr (Karakis S.)

1. Introduction

The earth's surface is in a state of constant change. Changes can be of natural origin as in earthquakes, landslides, etc., or anthropogenic in the form of mining or urbanization (Cao et al., 2023; Ren et al., 2019). Revealing change over time is important for inventory mapping, planning, and other retrospective studies aiming to understand the phenomena under investigation. Depending on the nature of the problem and the desired accuracy, change detection can be performed with point (e.g. GNSS deformation studies) and surface data (photogrammetric and remote sensing imagery) (Cook, 2017). While the first digital change detection studies in remote sensing were of 2 Dimensional origin, 3 Dimensional (3D) change detection studies have started to increase parallel to the developments in carrier platform, sensor, and computer technologies (Okuy et al., 2019; Théau, 2022).

Data acquisition can be provided by satellite, airborne, and unmanned aerial vehicle (UAV) platforms for change detection studies. However, airborne and UAV systems seem to be highly flexible for quick data capture providing high temporal resolution as well as high spatial resolution (Nex et al., 2022). In terms of endurance, airborne imaging is used to obtain data from larger areas, while UAVs are opted for imaging smaller areas due to their low battery life. Practitioners benefit from photogrammetric and LiDAR sensors attached to a UAV. However, the choice of imaging device is made for photogrammetric cameras since LiDAR implementation costs more and cannot be deployed on small UAVs. Thus, UAV photogrammetry can be operated easily and provides high spatial and temporal resolution imagery at low cost.

Whether acquired with LiDAR or a camera, the data set produced is a dense point cloud (PC). For change detection, the PC acquired in multiple epochs needs to be further processed. The preferred approach for evaluation depends on whether additional data processing is applied to the raw PC or not. There are four standard methods for extracting change information from reference and target PCs (de Gélis et al., 2021; Kharroubi et al., 2022; Li et al., 2024). These are cloud-to-cloud (C2C), cloud-to-mesh (C2M), multiscale model-to-model cloud comparison (M3C2), and DEM of difference (DoD). C2C compares cloud points across two epochs and does not require any additional data processing (Besl & McKay, 1992). C2M searches for the correspondence of the points in the reference PC and the mesh obtained from the target cloud. In the M3C2 method, the distance between the surface normal created at a point in the reference point cloud and the surface created in the target PC is estimated. The DoD approach requires more processing steps than the other three approaches, but it is more advantageous than these three methods in terms of processing time. Here, digital surface models (DSM) obtained at different epochs are compared grid by grid. To generate DSMs, it is necessary to form a triangular irregular network (TIN) by applying a triangulation algorithm to each PC and then interpolating the height value for each grid in the specified grid interval using the TIN surface (Wilson, 2012).

The most important feature of C2C, C2M, and M3C2 methods is that they can model the change between reference and target PCs as a vector. Unlike these methods, DoD can only reveal the change in the vertical direction. Few studies have undertaken simultaneous accuracy assessment of M3C2 and DoD approaches. For example, Nourbakhshbeidokhti et al. (2019) compared four methods including M3C2 and DoD approaches with reference data in the context of topographic and volumetric changes in channel sedimentation. Liu et al. (2023) determined the accuracy of the methods on 0.5 and 0.8 km long profiles using GPS measurements within a mining-induced subsidence monitoring project. In these studies, the two methods were compared indirectly using ground truth data in a limited part of the study areas. To the best of our knowledge, no study attempted to quantify the direct difference of both methods across a larger area, e.g. covering the entire study area. Thus, this study aims to compare the accuracies achieved by M3C2, which is the most effective of the three methods based on the processing of PCs to determine the change, and DoD, which is more optimal in terms of computation time.

2. Method

2.1 Study Area

The study area is located between 39.12521-39.13422N and 27.57405-27.58744E degrees and within the borders of Soma district of Manisa province, Türkiye. The heights of the area above the mean sea level vary between 680-865 m. The open pit mine field covers an area of 2.4 km² in total, where mining activities were first initiated in August 2021. The common area covered by the DSMs for the three epochs used in this study is 0.8 km². A landslide occurred in the north of the study area, and this was recorded in the last epoch survey. The fact that the area was hit by a landslide in addition to the change caused by mining activities played an important role in the selection of the area for a case study.

2.2 Data Processing

The study compares the reference DSM obtained from imagery at Epoch 0 (August 3, 2021) with the target DSMs generated for two distinct epochs. Epoch 1 images were taken at a temporally close (21 days) and Epoch 2 at a distant (256 days) interval from the reference Epoch 0. In all three epochs, images were acquired using a DJI Phantom UAV with the FC6310S camera model having a focal length of 8.8 mm and a square pixel size of 2.41 µm. The numerical data of the flights are presented in Table 1.

Table 1: Flight data for images used in the study

UAV Campaign	Days from the 0 th Epoch	Total Images	Altitude [m]	Mean Ground Sampling Distance (GSD) [cm]	Area [km ²]
Epoch 0 Aug2, 2021	0	401	270	6.9	1.86
Epoch 1 Aug23, 2021	21	454	220	5.8	0.80
Epoch 2 Apr15, 2022	256	587	230	5.8	2.42

Epoch 1 survey covers the smallest area as mining operations were concentrated to a limited section within 21 days after the excavation started in August 2021. In the 256 days after Epoch 0, activities spread over a wider area, so the imaging also covers a larger area. However, to make an effective comparison within the scope of the study, Epoch 1 covering the smallest area, was taken as the basis and the other two data sets were truncated to cover the area bounded by this area.

Photogrammetric orientations of the images were performed with Agisoft Photoscan software. After the image matching and relative orientation stages, dense matching was performed and PCs to be used in DSM production were obtained. The absolute orientation of the model was made by ground control points (GCP) and its check was conducted by independent check points (ICP). The coordinates of the control points were determined separately for each of the three epochs using GNSS relative positioning where a fixed station established in the field was taken as reference.

DSMs with 0.5 m grid spacing were produced with the PCs obtained after the photogrammetric dense matching stage. Inverse Distance Weighting (IDW) was preferred as the interpolation method. 3x3 dimensional low pass filtering was applied to the raw DSMs. The DSMs to be used in the comparison were thus made ready for DoD.

The other method used in the study is based on the comparison of 3D PCs at different epochs and finding the distance vector between the reference and target PCs. The M3C2 approach is used to compare PCs and the method works in two stages (URL-1). The working principle of the method is illustrated in Figure 1. In the first stage, a plane is estimated with the help of the points within the circle of diameter D created at a selected point in the reference PC, and the normal direction of this

plane is calculated. In the second stage, the average position for each cloud is found with the reference and compared points inside the cylinder of diameter d formed in the direction of the normal. In this way, the distance between the two average positions is obtained as the change vector (Lague et al., 2013).




Figure 1: Visual illustration of the M3C2 method (The figure in Lague et al. (2013) is slightly modified)

2.3 DoD and M3C2 Comparison

DoD is based on the principle of taking the algebraic differences of DSMs and obtaining the changes in the vertical direction (Williams, 2012). M3C2, on the other hand, uses a 3D point cloud to extract the difference vector between a point in the reference DSM cloud and its corresponding point in the compared DSM. Therefore, it is not possible to directly compare DoD and M3C2 results. To make a comparison, 3D coordinates of the corresponding point in the compared cloud must be found. For this, the 3D unit vector components n_x , n_y , and n_z and the distance value generated by M3C2 can be used. Using the unit vectors;

$$n_{XY} = \sqrt{n_x^2 + n_y^2} \tag{1}$$

$$A = \tan^{-1} \left(\frac{n_y}{n_x} \right) \tag{2}$$

$$Z = \tan^{-1} \left(\frac{n_{XY}}{n_z} \right) \tag{3}$$

azimuth and zenith angles are calculated. The transformation from polar to cartesian coordinates is performed by the following equations:

$$X_{\text{Compared}} = X_{\text{Ref}} + d \cdot \sin Z \cdot \cos A \tag{4}$$

$$Y_{\text{Compared}} = Y_{\text{Ref}} + d \cdot \sin Z \cdot \sin A \tag{5}$$

$$Z_{\text{Compared}} = Z_{\text{Ref}} + d \cdot \cos Z \tag{6}$$

Using the horizontal components (X, Y), the vertical component in the compared DSM is interpolated (Z_{int}). This height is then compared with the M3C2 height in the compared DSM ($Z_{\text{Compared}} - Z_{\text{int}}$).

The second comparison is designed according to the DoD approach. To facilitate this comparison, both DSMs were sampled at the production stage to correspond to the same grid node coordinates. Thus, a point taken on both DSMs and DoD corresponds to the same point horizontally on all three gridded surfaces. The comparison is based on whether the M3C2 reference and compared PC points are in the same DoD grid. In the obtained M3C2 solution, the points meeting this condition were separated and the M3C2 distance and DoD values at these points were compared.

3. Results and Discussion

Photogrammetric PCs were obtained with the processing software and the number of cloud points exceeded 10.3, 15.2, and 16.2 million for Epochs 0, 1, and 2, respectively. Triangulation and interpolation steps were applied to these point clouds to obtain DSMs with 0.5 m grid spacing (Figure 2). During the calculation of DSMs, vegetation areas were manually demarcated and excluded from the computation.

In the M3C2 assessment, subsampling of the reference PC was performed at 1 m intervals for reducing computation time and projection parameters were set as $D=0.14$ m and $d=0.28$ m. As can be seen, the parameters were set to 2 and 4 pixels respectively, so that the results are not affected by abrupt height changes, especially in areas close to the excavation boundaries. Epoch 0 was set as reference and correspondence of subsampled points at the other two epoch solutions were searched for. While Epoch 1 comparison delivered distances at all subsample points, M3C2 distances could be obtained for 67% of the extracted 500k Epoch 2 points. This can be explained by the fact that image matching in Epoch 2 generated fewer points in the excavated flat areas. Excavation works in Epoch 1 imaging time did not advance considerably; thus, better image matching was achieved in Epoch 1 than in Epoch 2 (Figure 3).

In order to compare DoD and M3C2 results, it is important to determine the accuracy of the height component. Threshold values for the statistical tests used in the comparisons were determined based on this accuracy value. In this context, the points whose coordinates were obtained by the GNSS method were divided into two subsets. GCPs were used for the estimation of the model's absolute orientation parameters and the remaining ICPs were used for model validation. As can be seen in Table 2, where the results of all three epochs are given, the values obtained with GCPs are more optimistic, while ICP results are more realistic when the ground sampling distance is considered (see Table 1).

Table 2: Accuracy values attained for each survey. X, Y, and Z coordinates are given in the WGS84 datum

Epoch	Number of GCPs / ICPs	RMSE XY [cm] GCPs / ICPs	RMSE Z [cm] GCPs / ICPs
0	11 / 8	1.2 / 8.6	1.6 / 8.6
1	7 / 8	3.3 / 3.6	1.5 / 4.7
2	13 / 15	2.6 / 4.7	1.7 / 8.2

Here, although the Z component accuracy obtained with ICP in Epoch 1 was the best, the accuracies in the other two epochs were close to each other. To make a realistic comparison, the RMSE value of the reference epoch was adopted for each DSM's vertical component accuracy, which is the worst accuracy value obtained with ICP. In the case of comparing two different DSMs, the absolute threshold value is computed as $1.96 \cdot \sqrt{2} \cdot RMSEZ = 23.8$ cm at 95% confidence level by applying error propagation with independence assumption of the variables (James et al., 2017). The threshold value is found 33.7 cm for comparing the height difference of two values. These values are adopted as the acceptance/rejection boundary to decide whether the difference values are significant in the comparisons made.

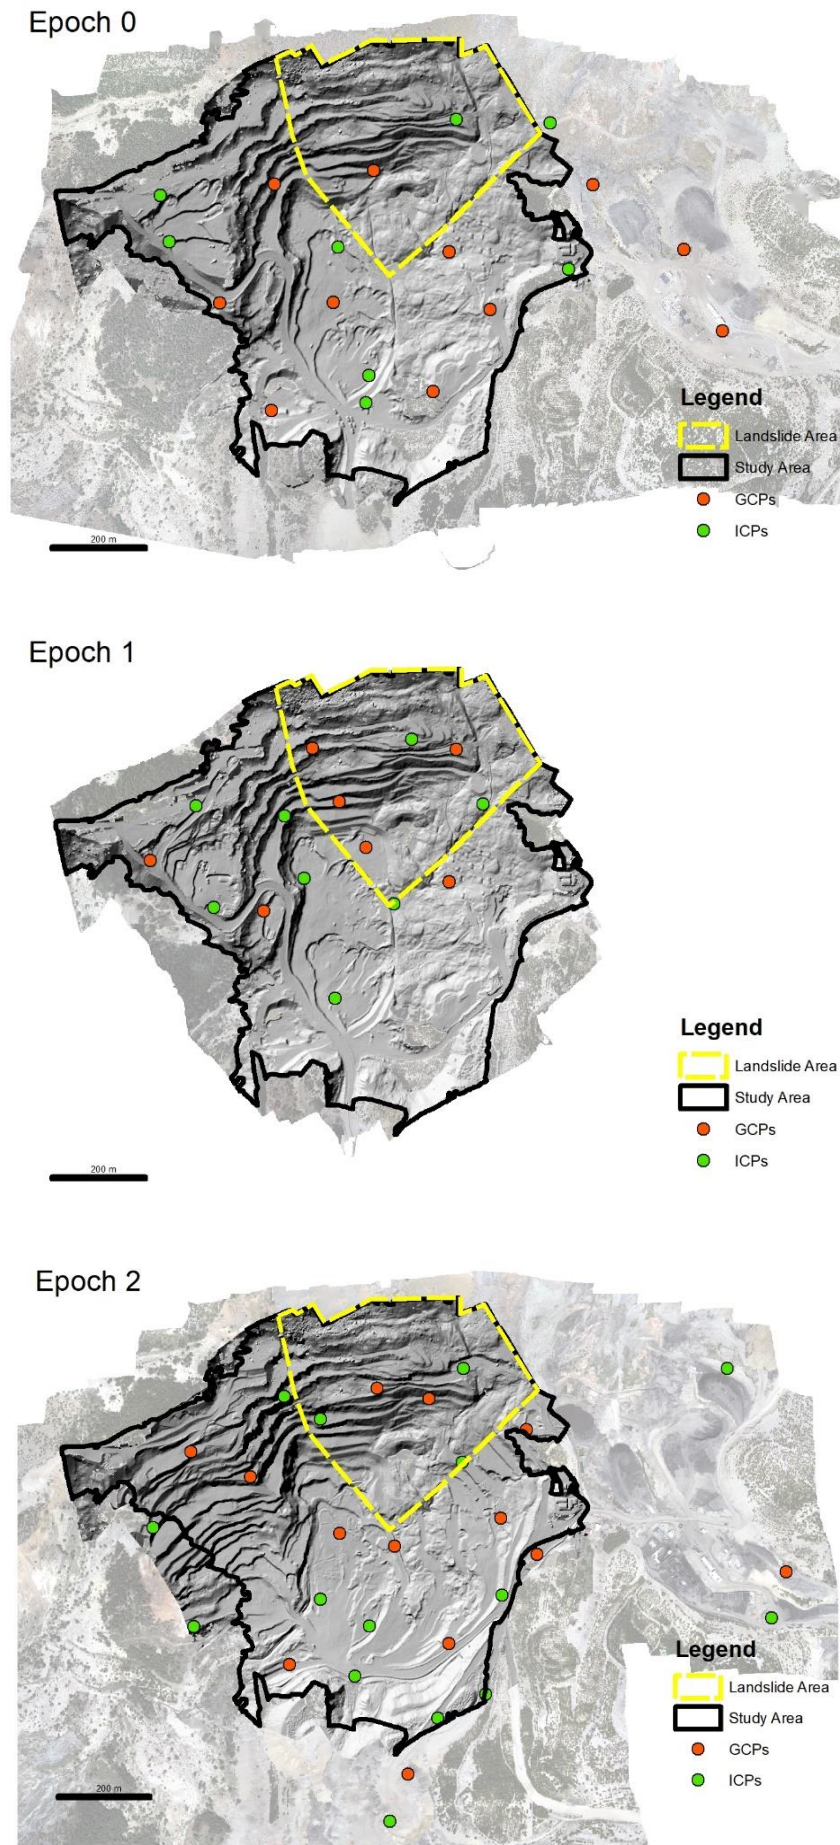


Figure 2: DSMs generated from photogrammetric PCs

The M3C2 solution delivers the 3D coordinates of the points in the reference epoch together with the 3D unit vectors and distance values of the change direction to the compared PC. The new 3D position of the changed point $(X, Y, Z)_{\text{Compared}}$ in the comparison PC is calculated by vector and distance values. The compared DSM value at this location was obtained by interpolation (Z_{int}) using the calculated horizontal components $(X, Y)_{\text{Compared}}$. The comparison results ($Z_{\text{int}} - Z_{\text{Compared}}$) for both epochs are presented in Table 3. The standard deviation values calculated with height differences for both epochs were close to each other. Outliers exceeding the threshold value of 23.8 cm in the comparison of the two data sets make up a small fraction of the entire data sets. Therefore, it can be said that although M3C2 and DOD offer different solution sets, they perform change detection for this study area successfully.

Table 3: M3C2 vs DSM comparison of heights

Data Set	Number of M3C2 Points	min / mean / max [m]	Std. Dev. of Differences [cm]	Number of Outliers / Percentage
Epoch 1	413 871	-6.45 / 0.01 / 12.81	10.8	6185 / 1.5 %
Epoch 2	366 893	-7.35 / 0.05 / 12.47	8.9	2676 / 0.7 %

For carrying out the second comparison, M3C2 points satisfying a condition were selected. This condition states that the start and end points of the distance vector found with the M3C2 solution must be within the same DoD grid. For this purpose, the geographical left and top extent values of all DSMs were initially set to the same value, so that the same grid nodes in each DSM show identical horizontal coordinates. M3C2 distance values and grid DoD values meeting this condition were compared. The numerical data of this comparison is presented in Table 4.

Table 4: M3C2 distance values vs DoD

Data Set	Number of Points / Percentage	min / mean / max [m]	Std. Dev. of Differences [cm]	Number of Outliers / Percentage
Epoch0 – Epoch1	346 320 / 83.7%	-1.94 / 0.025 / 4.83	8.6	2653 / 0.8%
Epoch0 – Epoch2	131 818 / 31.9%	-1.80 / -0.024 / 3.21	10.7	1544 / 1.2%

Difference values exceeding the threshold value of 33.7 cm were labeled as outliers and removed from the dataset. In Epoch 1, 83.7 of the total PC points fulfill the condition of being within the same DoD grid, while this ratio drops below one-third of all PC points obtained for Epoch 2. In Epoch 1 data taken 21 days after the mining activities started, a higher percentage of points could be obtained since the excavation works did not progress. On the other hand, fewer points could be evaluated in Epoch 2 data since excavation works spread over larger areas within 256 days and a landslide occurred on the site (Figure 3).

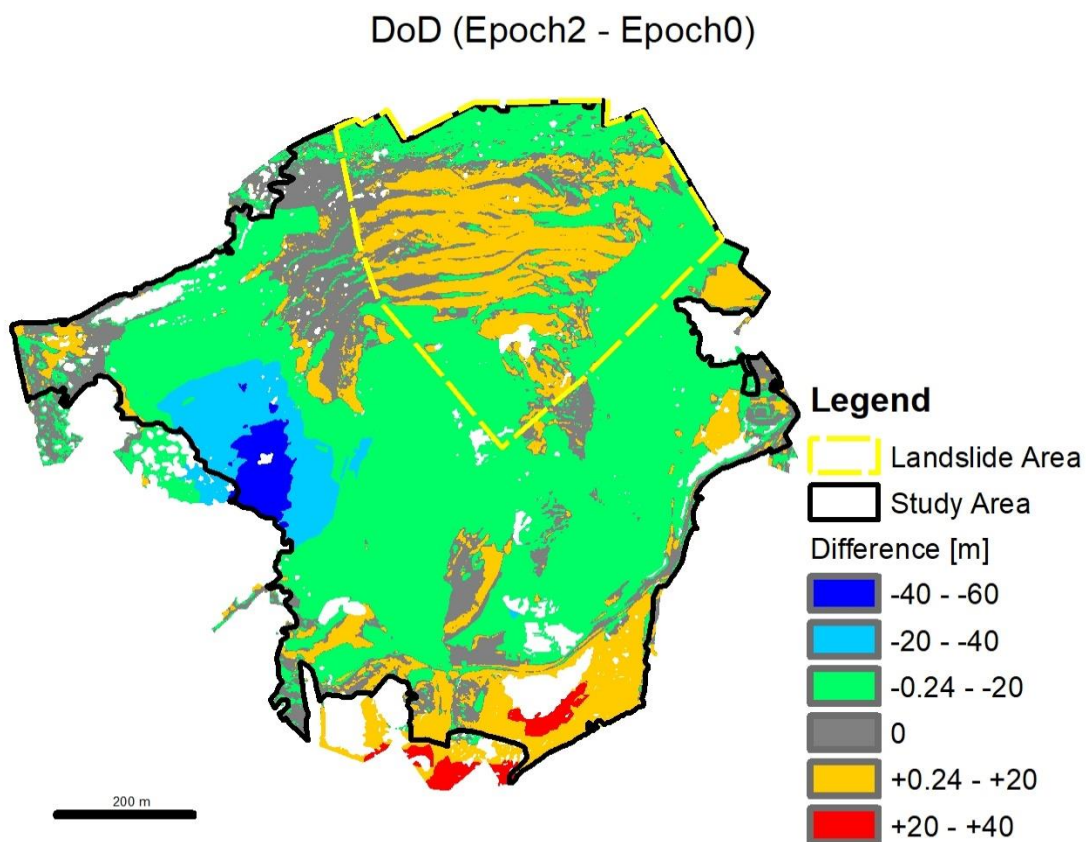
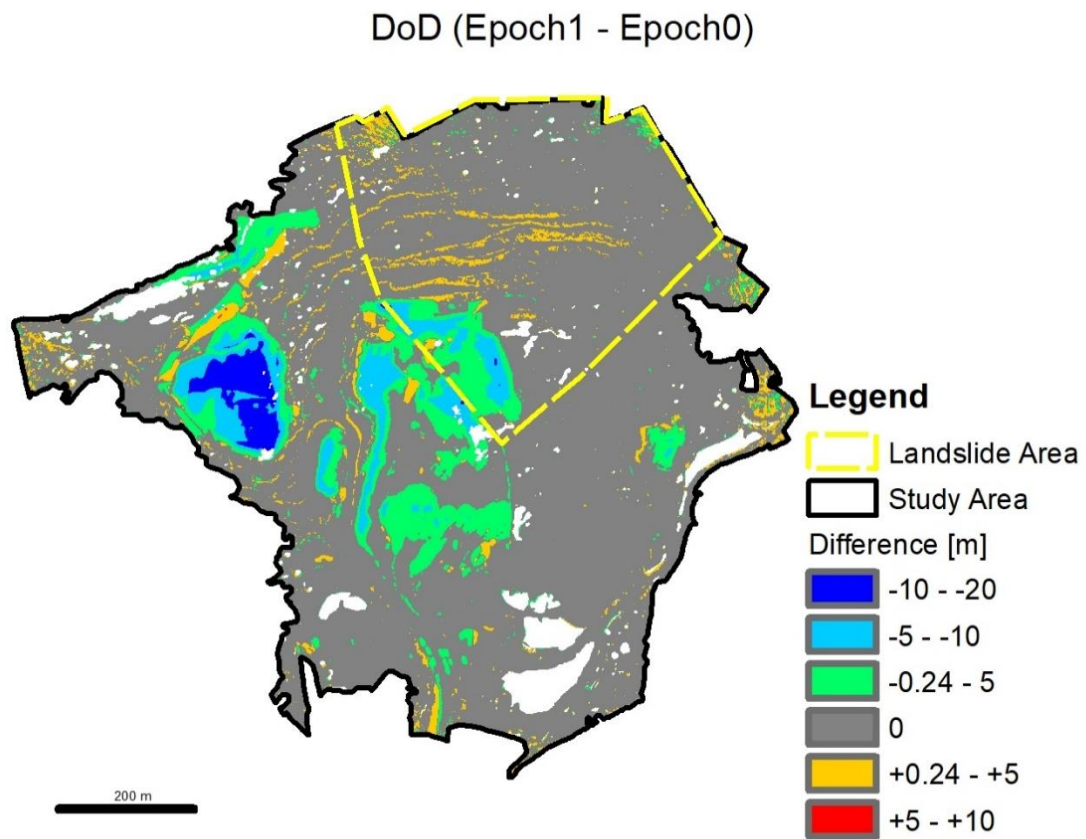


Figure 3: DoDs with reference to Epoch 0. Note separate difference scale for each plot.

4. Conclusion

In this study, two change detection methods, DoD and M3C2, are compared in an open pit mine case. A direct one-to-one comparison of the two methods is not possible given their outputs. For this reason, the coordinates of the distance vector produced by M3C2 and the corresponding point in the compared PC were calculated, and the DSM height values were interpolated with the calculated horizontal position values. The calculated and interpolated values were then compared. A second comparison was made with a limited set of points within the same DoD grid of the reference and compared PC points. In the case of the coexistence of excavation and landslide, both methods reveal the change. Since the M3C2 method also gives the direction of change, it can be preferred in modeling dynamic changes like landslides. DoD method is superior to M3C2 in terms of computation time in determining the change in vertical direction such as excavation and volume calculations.

Acknowledgements

We would like to express our sincere gratitude to FİDES Mühendislik for providing access to the UAV images used in this research.

Author Contribution

Nilufer Ozdas: Conceptualization, Methodology, Data processing, Writing-Original draft preparation. **Mehmet Guven Kocak:** Conceptualization, Methodology, Data processing, Writing-Original draft preparation, Reviewing and Editing. **Serkan Karakis:** Data processing, Reviewing, and Editing.

Declaration of Competing Interests

The authors declare that they have no known relevant competing financial or non-financial interests that could have appeared to influence the work reported in this paper.

References

- Besl, P. J., & McKay, N. D. (1992). A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2), 239-256.
- Cao, D., Zhang, B., Zhang, X., Yin, L., & Man, X. (2023). Optimization methods on dynamic monitoring of mineral reserves for open pit mine based on UAV oblique photogrammetry. *Measurement*, 207, 112364.
- Cook, K. L. (2017). An evaluation of the effectiveness of low-cost UAVs and structure from motion for geomorphic change detection. *Geomorphology*, 278, 195-208.
- de Gélis, I., Lefèvre, S., & Corpetti, T. (2021). Change detection in urban point clouds: An experimental comparison with simulated 3d datasets. *Remote Sensing*, 13(13), 2629.
- James, M. R., Robson, S., & Smith, M. W. (2017). 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. *Earth Surface Processes and Landforms*, 42(12), 1769-1788.
- Kharroubi, A., Poux, F., Ballouch, Z., Hajji, R., & Billen, R. (2022). Three dimensional change detection using point clouds: A review. *Geomatics*, 2(4), 457-485.
- Lague, D., Brodu, N., & Leroux, J. (2013). Accurate 3D comparison of complex topography with terrestrial laser scanner: Application to

- the Rangitikei canyon (NZ). *ISPRS journal of photogrammetry and remote sensing*, 82, 10-26.
- Li, P., Li, D., Hu, J., Fassnacht, F. E., Latifi, H., Yao, W., Gao, J., Chan, F.K.S., Dang, T., & Tang, F. (2024). Improving the application of UAV-LiDAR for erosion monitoring through accounting for uncertainty in DEM of difference. *Catena*, 234, 107534.
- Liu, X., Zhu, W., Lian, X., & Xu, X. (2023). Monitoring mining surface subsidence with multi-temporal three-dimensional unmanned aerial vehicle point cloud. *Remote Sensing*, 15(2), 374.
- Nex, F., Armenakis, C., Cramer, M., Cucci, D. A., Gerke, M., Honkavaara, E., Kukko, A., Persello, C., & Skaloud, J. (2022). UAV in the advent of the twenties: Where we stand and what is next. *ISPRS journal of photogrammetry and remote sensing*, 184, 215-242.
- Nourbakhshbeidokhti, S., Kinoshita, A. M., Chin, A., & Florsheim, J. L. (2019). A workflow to estimate topographic and volumetric changes and errors in channel sedimentation after disturbance. *Remote Sensing*, 11(5), 586.
- Okyay, U., Telling, J., Glennie, C. L., & Dietrich, W. E. (2019). Airborne lidar change detection: An overview of Earth sciences applications. *Earth-Science Reviews*, 198, 102929.
- Ren, H., Zhao, Y., Xiao, W., & Hu, Z. (2019). A review of UAV monitoring in mining areas: Current status and future perspectives. *International Journal of Coal Science & Technology*, 6, 320-333.
- Théau, J. (2022). *Change detection*. Kresse, W., & Danko, D. (ed) *Springer Handbook of Geographic Information*, Springer International Publishing.
- Williams, R. (2012). DEMs of difference. *Geomorphological Techniques*, 2(3.2).
- Wilson, J. P. (2012). Digital terrain modeling. *Geomorphology*, 137(1), 107-121.
- URL-1: CloudCompare (version 2.12.4) [GPL software], <http://www.cloudcompare.org/> (Accessed: 25 December 2023).

Coğrafi referanslı sosyal medya verilerinden doğal dil işleme ve derin öğrenme kullanılarak duygu analizi: Kahramanmaraş depremleri örneği

Dilan Gözdem Dolu^{1*}, Alper Şen¹

¹Yıldız Teknik Üniversitesi, Davutpaşa Kampüsü, İnşaat Fakültesi, Harita Mühendisliği Bölümü, Esenler, İstanbul.

Öz: Doğal afet yönetiminde afet öncesi hazırlık, afet anı müdahale ve afet sonrası iyileştirme aşamalarında Coğrafi Bilgi Sistemleri (CBS) kullanılarak uygulanan yönetim biçimleri ile doğal afetlerin yol açtığı zararlar en aza indirgenebilmektedir. Bu çalışmanın amacı, 6 Şubat 2023 tarihli Kahramanmaraş depremleri ile ilgili X (eskiden bilinen adıyla Twitter) sosyal medya verilerinin Python programlama dilinde Selenium ve BeautifulSoup kütüphaneleri kullanılarak kazınması ve doğal dil işleme ve derin öğrenme yöntemleri kullanılarak depremden etkilenen insanların afet sonrası duygu durumlarının incelenmesidir. Bu sayede, deprem anında bölge için genel duygu durumu ve sonrası için yapılacak sosyal ve psikolojik iyileştirme çalışmaları planlamalarının CBS ortamında daha hızlı ve kolay bir şekilde yapılmasına katkı sağlanabilecektir. Bu çalışmada, doğal dil işleme kapı yinlemeli birimler (Gated Recurrent Units, GRU) derin ağ modeli kullanılarak X platformundan kazanılmış ve düzenlenmiş veri kümesi üzerinde %87 test doğruluğu ile bir duygu analizi gerçekleştirilmiştir. Ayrıca CBS ortamında sıcak nokta analizi yapılarak yaşanan deprem ile ilgili X iletilerindeki duygu durumuna ait kümelenme örüntüsü istatistiksel olarak incelenmiştir. Böylece, yaşanabilecek depremler ile ilgili X platformuna ait coğrafi referanslı sosyal medya verilerinin duygu analizinde kullanılabileceği saptanmıştır.

Anahtar Sözcükler: Deprem, Coğrafi referanslı sosyal medya verileri, Web kazıma, Duygu analizi, Doğal dil işleme, Derin öğrenme

Sentiment analysis from georeferenced social media data using natural language processing and deep learning: The case of Kahramanmaraş earthquakes

Abstract: In natural disaster management, the damages caused by natural disasters can be minimized by using Geographic Information Systems (GIS) in pre-disaster preparation, disaster response and post-disaster recovery stages. The aim of this study is to scrape X (formerly known as Twitter) social media data related to the Kahramanmaraş earthquakes on February 6, 2023 using Selenium and BeautifulSoup libraries in Python programming language, and to examine the post-disaster emotional states of people affected by the earthquake using natural language processing and deep learning methods. Thus, it will be possible to contribute to the planning of the general emotional state of the region at the time of the earthquake and the social and psychological rehabilitation activities to be carried out afterwards in a faster and easier way in the GIS environment. In this study, a sentiment analysis was performed with 87% test accuracy on the scraped and organized dataset from the X platform using the Gated Recurrent Units (GRU) deep network model in natural language processing. In addition, by performing hot spot analysis in the GIS environment, the clustering pattern of the emotional state in X messages related to the earthquake occurred was statistically analyzed. Thus, it was determined that georeferenced social media data of the X platform related to possible earthquakes can be used in sentiment analysis.

Keywords: Earthquake, Georeferenced social media data, Web scraping, Sentiment analysis, Natural language processing, Deep learning

* Sorumlu Yazar/Corresponding Author: Tel: +90 212 383 5344

Geliş Tarihi/Received: 14.01.2024
Kabul Tarihi/Accepted: 26.03.2024



0000-0002-9585-4054, gozlem.dolu@std.yildiz.edu.tr (Dolu D. G.)*
0000-0002-7236-6701, alpersen@yildiz.edu.tr (Şen A.)

1. Giriş

Modern teknolojinin hızlı gelişmeleri sayesinde sensör ağları ve uzaktan algılama tekniklerinin kurulması yoluyla doğal afetlerin izlenmesi, önceden uyarılması ve afetlerden sonra yaşanan durumların genel incelenmesi mümkün hale gelmiştir (Feng vd., 2022). Doğal afet yönetiminde de afet öncesi hazırlık, afet anı müdahale ve afet sonrası iyileştirme aşamaları mevcuttur (Neal, 1997). Doğal afetlerin yönetiminde Coğrafi Bilgi Sistemlerinin (CBS) 1960'larda teknoloji ile mantık arasındaki bağlantıyı ortaya çıkarmasıyla başlayan süreç (Clarke, 1997), günümüzde afet yönetimi aşamalarında yaygın bir şekilde diğer sistemlerle entegre edilen CBS'nin kullanımıyla devam etmektedir. Bu bütünleşmiş sistemlerden biri de sosyal medyadır. Sosyal medya, X (eskiden bilinen adıyla Twitter) ve Threads gibi küresel ölçekte yaygın kullanılan platformlarıyla geniş bir kullanıcı kitlesine erişim sağlar. Kullanıcılar paylaşımlarıyla sosyal medyayı haberleri, etkinlikleri veya ürünleri değerlendirdikleri, kendi düşüncelerini ve duygularını aktardıkları bir platform olarak görürler. Sosyal medya verileri, işletmeciler için ürünleri ve piyasadaki marka izlenimleri hakkında bilgi verebileceği gibi sosyal olaylardan sonra vatandaşların duygu durumlarını da analiz etmek için kullanılabilir. Elde edilen verilerin analizleri piyasa fiyat izleme ve planlama çalışmalarında oldukça yaygın kullanılmaktadır. Bu durum, sosyal medya veri işleminin çalışmalarda sık kullanılmasına ve kullanımının artmasına neden olmaktadır (Bhardwaj vd., 2015).

Sosyal medya kaynağının sağladığı çeşitli mekânsal verilerin kullanılması ile ilgi noktalarının belirlenmesi, olayların zamansal ve mekânsal dağılımının değerlendirilmesi, belirli bir zamanda ve mekânda olayların yoğunluğunun belirlenmesi gibi farklı mekânsal problemlerin analizlerine katkı sağlamak mümkündür. Sosyal medya üzerinden anlık veri çekilebilmesi, büyük ve çeşitli veriler sağlanabilmesi nedeniyle potansiyel uygulama alanlarından biri doğal afetlerdir (İlhan & Sağaltıcı, 2020). Sosyal medya içerisindeki bilgiler veri kazıma ile elde edildikten sonra farklı analizlerde kullanılarak müdahale ve iyileştirme çalışmalarına katkı sağlanabilir. Sosyal medya platformları uzun metinler, net fotoğraflar, mekânsal bilgiler ve uzun videolar gibi kaliteli bilgileri içerisinde barındırmaktadır. Sosyal medyadan bilgi verimli bir şekilde elde edilebilir; metin ve görsellerin yorumlanmasıyla yeni içerikler elde edilebilir (Feng vd., 2022). Mekânsal veriler çalışmalarda coğrafi etiketli veriye dayalı uygulamalar için kullanılabilirken, metinsel veriler duygu analizinin yapılması gibi çeşitli uygulama alanlarında kullanılabilir. Sosyal medya verileri, doğal dil işleme (Natural Language Processing, NLP) tekniklerinden biri olan duygu analizinde de kullanılabilir (Adalı, 2012). Duygu analizi yapılırken birçok makine öğrenmesi yöntemi uygulanabilir. Bunlardan biri olan derin evrişimli sinir ağları sayesinde bilgisayarlı görü (computer vision) ve doğal dil işlemede büyük ilerleme sağlanmıştır (Feng vd., 2022).

Son yıllarda deprem gibi doğal afetler için sosyal medya verilerinin araştırılması ve analizi sayesinde elde edilen bilgilerin coğrafi bilgi sistemleri ile kullanılması önem arz eder. Sosyal medya platformları metinler, coğrafi konumlar, fotoğraflar, videolar ve sesler gibi veri çeşitlerini içerisinde barındırır. Bu platformlar, kullanıcıların farklı içerikleri paylaşmasına ve etkileşimde bulunmasına olanak tanır ve böylece kullanıcılar arasında bilgi paylaşımı sağlanır. Sosyal medya veri kazıma çalışmalarından elde edilen metinler üzerinden zamansal ve mekânsal (geometrik ve semantik) veriler elde edilebilir. Veri kazıma sonucu elde edilen iletilerin zaman dilimi, konuları ve kullanıcıların iletilerinin gönderimi sırasında paylaşım açtıkları konum bilgileri elde edilebilir (Kaya, 2021). Sosyal medya ortamında mevcut olabilen konum bilgisi, kullanıcılarının iletiyi paylaştıkları yerin coğrafi konum bilgileri, sözel olarak yer alan kullanıcı profilindeki yerleşim yeri, paylaşımlarında bahsedilen konumlar ve doğrudan paylaşılan enlem-boyam gibi konumlar aracılığıyla belirlenebilir (Gulnerman & Karaman, 2020). Mekânsal veri analizi, verilerin mekânda nasıl etkileşime girdiğini yöntemlerle incelerken, aynı zamanda bu verilerin diğer mekânsal vakalarla olan bağlantılarını araştıran bir yaklaşımdır. Bu tür analizler, değişkenlerin mekânsal dağılımını anlamayı, örüntülerin tanımlanmasını, mekânsal kümelenmeyi ve değişkenler arasındaki bağlantıları çözümlenmeyi amaçlayan çeşitli teknikleri içerir (Özgür & Aydın, 2011).


Sosyal medya verileri kullanılarak yapılan mekânsal analiz çalışmaları şu şekilde sıralanabilir: Zhou ve Xu (2017) tarafından, New York City - Washington DC bölgesindeki olayların X verileri üzerinden mekânsal ve zamansal dağılımları incelenmiştir. Bu çalışmada, Geo API'den toplanan Küresel Konumlama Sistemi (Global Positioning System, GPS) bilgisini içeren iletiler kullanılmıştır. Geo API'den toplanan iletilerde konum içeriği, zaman dilimleri, yer adları ve GPS ölçümleri gibi en az bir tür konum verisi bulunur. Elde edilen veriler içerisinde yağmur gibi rastgele olayların yanı sıra planlı etkinlikler ile ilgili, örneğin Papa'nın ziyareti gibi, konuların X kullanıcıları üzerindeki etkileşimleri belirlenmiştir. Rastgele orman algoritması ve mekânsal-zamansal analizler kullanılarak incelenen olayların, X platformundaki iletilerde artışa neden olduğu tespit edilmiştir. X üzerinden olaylara olan anlık tepkileri ve ilgili mekânsal-zamansal örüntüleri belirleyerek sosyal medyadaki etkileşimleri anlamaya yönelik bir metodoloji sunmuştur. Wang vd. (2018) tarafından, doğal afetlerden biri olan sel konusundaki sorunlar hakkında X üzerinden API ile elde edilen veriler kullanılarak NLP ve bilgisayarlı görü teknikleri ile bir yaklaşım belirlenmiş; X tabanlı verilerin sokak adları ölçeğinde hassasiyet sağladığı tespit edilmiştir. Gulnerman ve Karaman (2020) tarafından yakınlık analizi kapsamında kent yol ağı poligon kırık noktalarından Voronoi alanları üretilerek bu alanlarda gönderilen iletilerden yer adları elde edilmiş ve bir coğrafi sözlük üretilmiştir. Gulnerman vd. (2020a) tarafından, coğrafi ileti indiricisi (Geo Tweets Downloader, GTD) adlı sistem ile elde edilen coğrafi etiketli verilerden mekânsal bilgilere ulaşılmıştır. GTD, coğrafi etiketi olmayan iletileri atlayabilen, X API'leri kullanarak gerçek zamanlı olarak genel durum iletilerini sağlayabilen ve bu iletilerin coğrafi etiketleri de dahil olmak üzere çeşitli bilgilerini toplayabilen bir sistemdir. Bu çalışmada, İstanbul'daki kullanıcıların sosyal medya verileri ile davranışlarını anlamaya yönelik bir inceleme yapılmıştır. Veri analizi ile kullanıcı etkinliklerinin temsil düzeylerinin, mekân-zaman önyargılarının ve şehirdeki trendlerin belirlenmesi çalışmaları gerçekleştirilmiştir. Aktif kullanıcıların verilerinin temizlenmesi, farklı temsil düzeylerinin vurgulanması ve mekânsal-zamansal anomali eğilimlerinin tespit edilmesi gibi yöntemler kullanılarak elde edilen bulguların, şehirdeki günlük rutinlerin tarafsız bir şekilde ortaya çıkarılmasına yönelik potansiyel bir çerçeve sunduğu gösterilmiştir. Sonuç olarak sosyal medya verilerinin acil durumlar veya olağan dışı olayların tespitinde ve şehirdeki vatandaş davranışlarını izleme sistemi oluşturulmasında kullanılabilecek önemli verileri sağladığı vurgulanmıştır. Camacho vd. (2021) tarafından kullanıcıların profilinde belirttikleri konum bilgileri ve iletilerin içerdiği yer adları kullanılarak coğrafi kodlama işlemi gerçekleştirilmiştir. Kullanıcıların profil bilgilerinde belirttikleri konumlar ve iletilerin içeriğinde geçen yer adları, bir coğrafi kodlama hizmeti olan Geocodio aracılığıyla koordinatlara dönüştürülerek mekânsal bilgiler elde edilmiştir. Bu çalışmada, sosyal medyadaki doğal gazla ilgili paylaşımların duygusal içeriği incelenerek mekânsal dağılımı ele alınmıştır. Çeşitli duyarlılık analizi yöntemleri ve makine öğrenmesi modelleri kullanılarak paylaşımlar duygusal kategorilere ayrılmış ve coğrafi konumları belirlenmiştir. Amerika Birleşik Devletleri'nin farklı bölgelerinde doğal gazla ilgili paylaşımların duygusal dağılımı gösterilerek, zaman içinde duygusal içeriğin değişimi de ortaya konmuştur. Duygu analizi ve mekânsal analiz yöntemleri entegre edilerek sosyal medyadaki duygusal içeriğin coğrafi dağılımı sunulmuştur. Gulnerman vd. (2020b) tarafından, sosyal medya üzerinden GTD kullanılarak veriler elde edilmiş; coğrafi koordinatlara sahip iletilerin bilgisi mekânsal analiz ve metin analizi ile birleştirilerek olayları anlama sürecine katkı sağlanması amaçlanmıştır. Mekânsal verilerden daha kesin bilgi çıkarımını belirlemek için optimize edilmiş sıcak nokta analizi ile belirli bir zamanda ve mekânda olayların yoğunluğunun belirleme çalışması yapılmıştır. Bu çalışmada, coğrafi referanslı sosyal medya verilerinin acil durum izlemede faydalı olabileceği ele alınmıştır. Feng vd. (2022) tarafından, doğal afetlerle ilgili sosyal medya içeriği analiz edilmiş ve bu verilerden hangi bilgilerin elde edilebileceği ve bunların nasıl kullanılabileceği incelenmiştir. İlk olarak, sosyal medya üzerindeki doğal afet odaklı yayınlar sekiz farklı adımda sınıflandırılmış ve bu verilerin kullanımındaki zorluklar ve fırsatlar tartışılmıştır. Yapılan derleme çalışmasında, sosyal medyanın doğal afetlerle ilgili bilgi çıkarımında ve kullanımında karşılaşılan çeşitli zorluklara ışık tutmuşlardır. Sosyal medyanın doğal afetlerle ilgili veri toplamadaki ve veri analizindeki potansiyelini aynı zamanda da zorluklarını ortaya koyarak mevcut çözümler ile birlikte yeni araştırma fırsatlarını vurgulamışlardır.

X platformu sunduğu özelliklerden dolayı olayların anlık takibini sağlamada eşsiz bir değer sunmaktadır. Kullanıcılar, herhangi bir zamanda ve konumdayken anlık bilgi paylaşımı yaparak, adeta sosyal sensörler gibi işlev görmektedirler (Zhou & Xu, 2017). Afetlerin ardından, toplumun normale dönebilmesi için sadece temel ihtiyaçların değil, bireylerin psikolojik olarak da desteklenmesi gereklidir (Koç & Yalçın, 2023). Aile ve Sosyal Hizmetler Bakanlığının afet süreçlerinde sorumlu olduğu üç ana görev; aynı bağışların depolanması ve dağıtılması, psikososyal desteklerin sağlanması ve risk altındaki gruplara yönelik sosyal çalışmaların yapılmasıdır (2828 sayılı Sosyal Hizmetler Kanunu, 1983; URL-1; URL-2). Psikososyal destek, afet sürecinde oluşabilecek psikolojik sorunları önlerken, insanların topluma uyum sağlamasına, günlük hayata geri dönmesine ve afetle başa çıkma becerilerini geliştirmesine yardımcı olmaktadır (URL-3). AFAD'ın 1 Mart 2023 tarihli basın açıklamasına göre Aile ve Sosyal Hizmetler Bakanlığı, psikososyal destek hizmetleri kapsamında; Kahramanmaraş, Hatay, Osmaniye ve Malatya illerine dört adet mobil sosyal hizmet merkezi kurmuştur (URL-4).

Bu çalışmanın amacı, deprem sonrasında sosyal medya platformuna gönderilen coğrafi referans içeren iletilerin derin öğrenme kullanılarak yapılan duygu analizinin performansının tespit edilmesidir. Bu çalışmada, 6 Şubat 2023 tarihli Kahramanmaraş depremlerinin bölge ve insanlar üzerindeki etkilerinin incelenmesi amacıyla X (eskiden bilinen adıyla Twitter) sosyal medya verileri kullanılarak bir duygu analizi gerçekleştirilmiştir. Python programlama dilinde Selenium ve BeautifulSoup kütüphaneleri kullanılarak verilerin kazınmasının ardından, doğal dil işleme ve kapı yinelenmeli birimler derin ağ modeli kullanılarak depremden etkilenen insanların afet sonrası duygu durumlarının incelenmesi gerçekleştirilmiştir. Bu sayede, deprem sonrasında bölge için genel duygu durumu elde edilebilir. Deprem sonrası için yapılan duygu analizi CBS ortamında sıcak nokta analizleri, zaman-değişim analizleri, yoğunluk analizleri gibi analizlerle kullanılabilir. Bu analizler sayesinde belirli ihtiyaçların ve duygusal tepkilerin yoğunlaştığı bölgeler belirlenebilir. Kaynakların bu ihtiyaçlara ve bölgelere göre verimli kullanılması sayesinde psikososyal destek ekiplerinin güçlerini en etkin şekilde kullanmalarına yardımcı olması sağlanabilir. Ayrıca, deprem bölgesinden gönderilen ileti sayıları CBS ortamında korople (renk tonlu) harita ile gösterilmiş ve sıcak nokta analizi yapılarak iletilerdeki kümelenme örüntüsünün varlığı da incelenmiştir. Doğal dil işleme ve derin öğrenme yöntemleri kullanılarak geliştirilen modelin eğitimi sonucunda %87 test doğruluğu elde edilmiştir. Böylece deprem sonrası duygu analizinde sosyal veri kazıma kaynağı olarak X platformunun kullanılabilirliği ve elde edilen sosyal medya verilerinin duygu analizi ile sınıflandırılabilirliği saptanmıştır.

2. Yöntem

Bu çalışmada, 6 Şubat 2023 tarihli Kahramanmaraş depremlerinin bölge ve insanlar üzerindeki etkilerinin incelenmesi amacıyla X (eskiden bilinen adıyla Twitter) sosyal medya verileri kullanılmıştır. Çalışma; X platformundan veri kazıma ile metinsel veri setinin elde edilmesi, doğal dil işleme aşamaları, duygu analizi modelini eğitime, doğruluğunu test etme ve sıcak nokta analizi aşamalarından oluşmaktadır. Bu çalışmada kullanılan akış diyagramı Şekil 1'de gösterilmiştir.



Şekil 1: Çalışmaya ait akış diyagramı

2.1 Veri Kazıma

İnsanların fikirlerini ve bilgi dağarcığını sosyal medya platformları aracılığıyla paylaşmaları büyük veri setlerinin keşfedilmesine yol açmıştır. Bu veri setleri, makine öğrenimi ve veri madenciliği gibi yöntemlerle incelenerek ileriye

öngörmesi aynı zamanda da gizli örüntüleri çıkarması gibi amaçlar için kullanılmaktadır (Albayrak vd., 2017). Bu çalışmada, X sosyal medya platformu üzerinden veri kazıma işlemi gerçekleştirilmiştir. Veriler elde edilirken X platformundan veriyi otomatik ve hızlı bir şekilde kazımak adına Adana, Adıyaman, Batman, Bingöl, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş, Kayseri, Kilis, Malatya, Mardin, Niğde, Osmaniye, Şanlıurfa ve Tunceli bölgelerinden 685 adet gönderinin kazıma işlemi yapılmıştır.

Büyük verilerin hızlı, otomatik ve sürekli bir şekilde elde edilmesini sağlayan internette veri kazıma işlemi iki adımda yapılabilir. Bu adımlardan ilki internet kaynaklarının elde edilmesi, diğeri ise elde edilen verilerden istenen bilgilerin çıkarılması işlemidir (Zhao, 2017).

İnternet sitelerinin metin tabanlı bir biçimlendirme dili vardır. Bunlardan en yaygın olanı HTML ve XML'dir. Metin tabanlı biçimlendirme dili sayfanın içeriğini tanımlar ve bu sayede içeriğinde olan evrensel biçimleri ve işaretleme dillerinin etiketleri sayesinde istenen bilgiyi almak kolaylaşır. BeautifulSoup kütüphanesi de sayfa kaynağı HTML veya XML olan belgeleri ayrıştırmak için kullanılır (Kılınç vd., 2022). Bu sayede işlenmekte olan ayrıştırmanın kodlamasını otomatik bir şekilde algılayabilir ve bunu istemci tarafından okunabilir bir kodlamaya dönüştürerek anlaşılabilir olmasını sağlar (Zhao, 2017). Bu işlem gerçekleştirilirken sayfa kaynağında bulunan XPath, sınıf ve işaretleme etiketlerinden yararlanır. İşleme sırası ise ilk olarak sayfa içerisinde bütün bilgileri içeren kaynağı indirip içerisinden özellikle istenilen bilgilerin "find_all" çağırısıyla elde edilmesi şeklinde ilerlemektedir (URL-6).

BeautifulSoup kütüphanesi HTML kodundaki bilgileri ayrıştırmaya ve çıkarmaya yönelik bir modüldür. Selenium ise Google Chrome ve Internet Explorer gibi web tarayıcısı ile bağlantı kurup bunun üzerinden kimlik doğrulama, yeniden yönlendirme, çerezler gibi http istekleri ve sosyal medya platformlarına giriş yapmada istenen bilgilerinin otomatik girilmesini sağlayan Python kütüphanesidir. Temelde tarayıcı sürücülerini (web driver) üzerinden komutları takip ve kabul eden, bunları bir tarayıcıya gönderen otomasyon çerçevesidir (Zhao, 2017). Bu çalışmada, tarayıcı sürücülerinden Google Chrome seçilmiştir. Bu bağlantılarda önemli olan bir diğeri faktör ise kullanılan tarayıcının güncel olmasıdır.

Python programlama dili ile yazılan veri kazıma işleminin akış diyagramı Şekil 2'de gösterilmiştir. X platformundan veri kazıma işleminde tarayıcı sunucu üzerinden işlemlerin optimizasyonu için Selenium kütüphanesi, sayfa kaynağını indirmek için BeautifulSoup ve kazıma sonucu elde edilen verileri bir veri çerçevesine aktarmak için Pandas kütüphaneleri eklenir (Şekil 2a). Tarayıcı sürücünün başlatılması işlemi için Google Chrome sunucularına bağlanılarak X uygulamasına ait internet sayfasına bağlanılır (Şekil 2b). Oturum açma işlemi için kullanıcı adı ve şifrenin koda eklenmesi ile internet sayfasında uygun girişlere gerekli bilgilerin girilmesi işlemi gerçekleştirilir (Şekil 2c). 6 Şubat 2023 anahtar kelimesi (örneğin, "6 Şubat 2023" geocode:39.1070000,39.5472000,30km and "6 Şubat 2023", since:2023-06-01 until:2023-09-30) enlem, boylam, arama çapı ve tarih aralığı gibi bilgilerle birlikte kullanılarak kodun arama sonuçlarını açması işlemi gerçekleştirilir (Şekil 2ç). Sayfa kaynağını yüklemek amacıyla BeautifulSoup kütüphanesi kullanılarak XML formatında sayfanın içeriği indirilir. Bu sayede istenilen anahtar kelime ile elde edilen arama sonuçlarına ait sayfa kaynağı sağlanır. Sayfa kaynağı içerisinden XPath'ler sayesinde istenilen metin ve konum bilgilerinin elde edilmesi için ortam hazırlanır (Şekil 2d). X uygulamasından alınacak iletilerin bir liste içine eklenmesi için ve döngülerde kullanılan döngü tekrar başlangıç sayısı ve maksimum döngü tekrar sayısının tanımlanması işlemi gerçekleştirilir (Şekil 2e). İlk sayfadaki iletilerin XPath'leri alınır ve sayfa kaynağında bulunan ilk sayfadaki iletiler listeye eklenerek gönderi listesi oluşturulur (Şekil 2f). İletilerin gönderi listesine ekleme işlemi gerçekleştirilir. İlk gönderiden başlayarak sayfada bulunan tüm iletilerin teker teker listeye eklenmesi için döngü oluşturulur (Şekil 2g). İlk sayfadan alınan iletilerden sonra diğeri sayfalardan da iletilerin alınması için otomatik kaydırma işlemi gerçekleştirilir (Şekil 2ğ). Tekrarlayan gönderilerden arınmış bir liste oluşturmak amacıyla yeni bir gönderi listesi oluşturulur.

Yeni gönderi listesine, eski gönderi listesinde birden fazla aynı olan iletilerden yalnızca birinin alınması sağlanır. Böylece tekrarlı iletilerden arındırılır (Şekil 2h). Gönderi listesinin 200 adet iletiyi geçip geçmediği kontrol edilir. 200 adet ileti listeye alındıktan sonra kod çalışmayı durdurur (Şekil 2ı). Eğer 200 adetten az ileti varsa döngü 10 kez çalıştırılır. Döngü sayısı maksimum döngü sayısına ulaştığında kod çalışmayı durdurur (Şekil 2i). Döngüden gelen her ileti gönderi listesine eklenir (Şekil 2j). Tekrardan arındırılmış gönderi listesi bir veri çerçevesi içerisine yazdırılır (Şekil 2k).

2.2 Doğal Dil İşleme

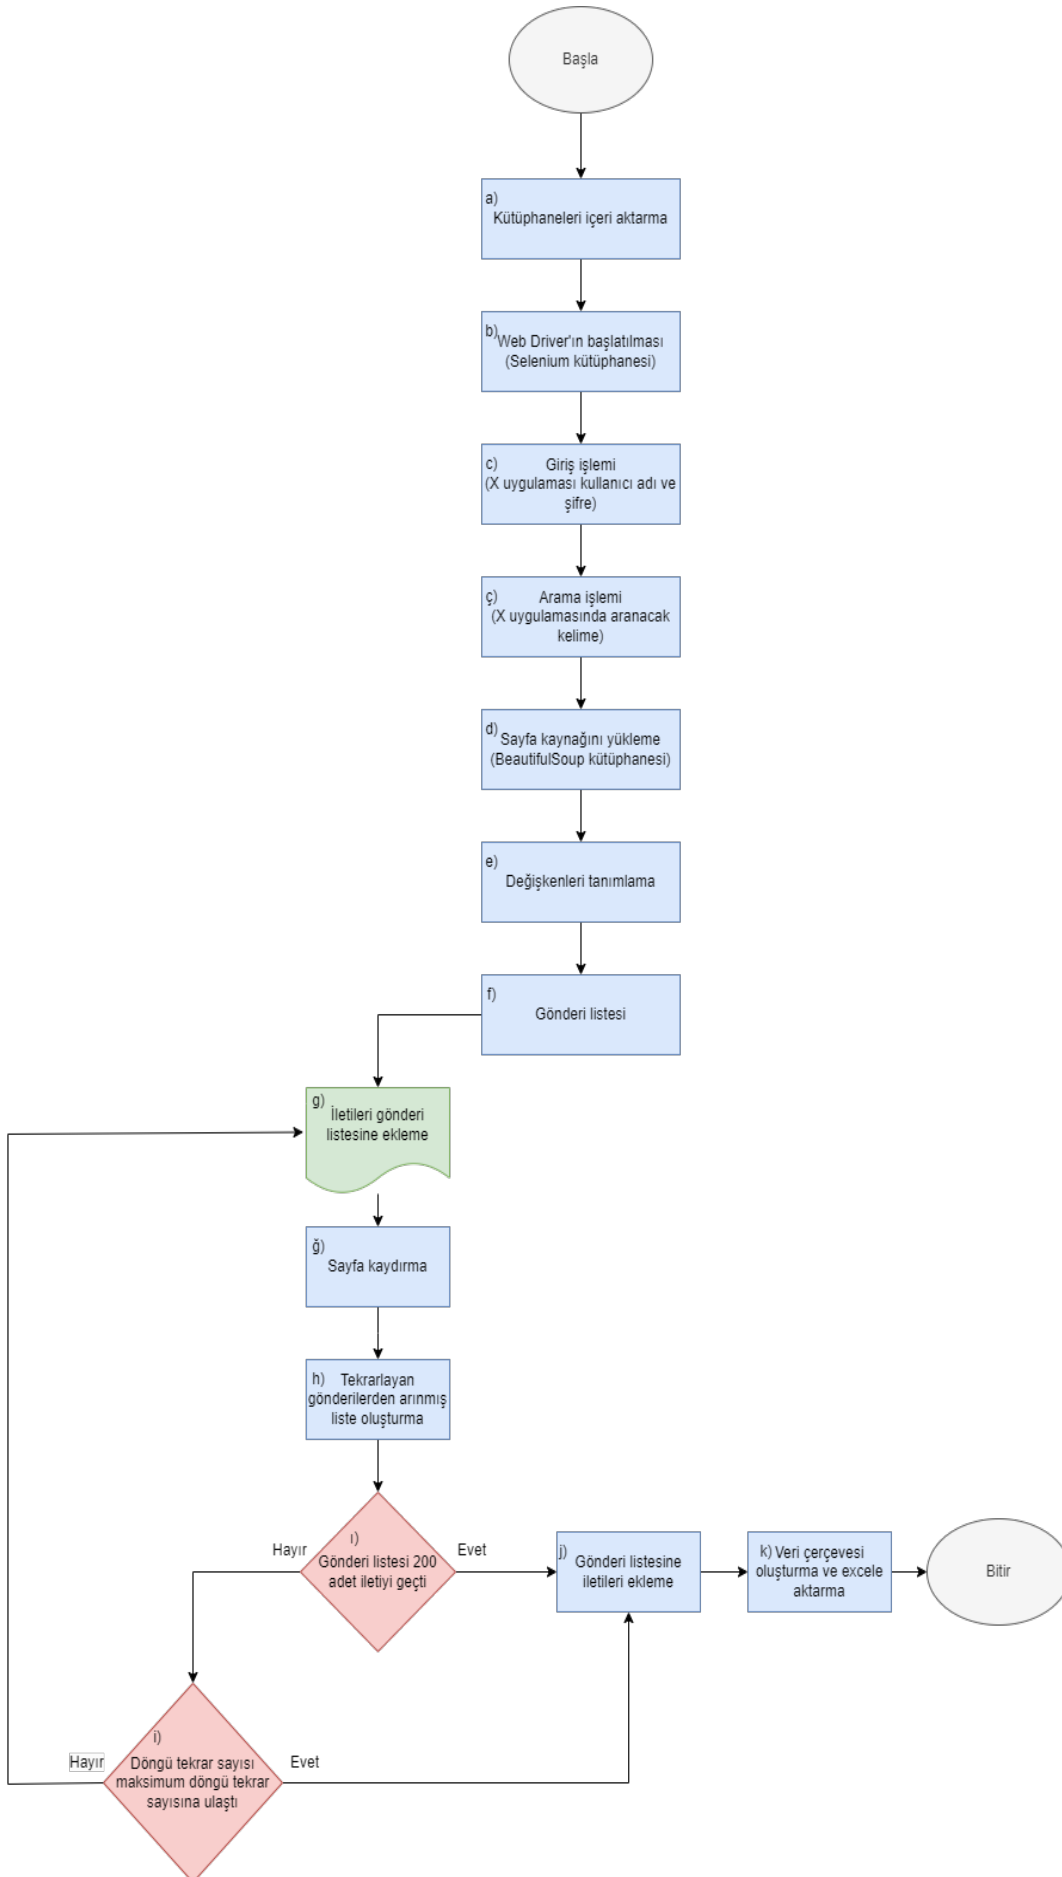
Diller, makine dili ve insanlar tarafından kullanılan doğal dil olarak ikiye ayrılmaktadır. Doğal dillerin makineler tarafından algılanması ve gerektiğinde diller arası bağlantının kurulup çözümlenmesini doğal dil işleme sağlamaktadır (Şeker, 2015). Doğal dil işleme; yapay zekâ alanında bilgisayarların insan dilini anlama, yorumlama ve bu dili kullanarak metinleri veya konuşmaları analiz etme kabiliyetlerini geliştiren bir alt daldır. Bu teknoloji, metinleri sadece kelime düzeyinde anlamakla kalmayıp, cümlelerin ve paragrafların içerdiği anlamı da çözümlenmeyi hedefler (Häberle vd., 2019). Doğal dil işleme günümüzde yaygın olarak diller arası çeviri, mobil telefonlardaki akıllı asistanlar ve çözüm odaklı kullandığımız ChatGPT gibi yapay zekâ asistanlarının temelinde kullanılır (Adalı, 2012). Doğal dil işleme, metinlerin analizlerde kullanılabilir hale getirilmesini sağlayan dil işleme tekniklerini içermektedir (Şeker, 2015).

Hazırlanan veri setine duygu analizi uygulandığında metnin duygusal olarak ne ifade ettiğinin çıkarımı yapılır. Duygu analizi temelde bir metnin pozitif, negatif veya nötr duygularla yazılmış olma durumunu ortaya çıkarır (Albayrak vd., 2017). Pozitif ve negatif duygu çıkarımı yapılabildiği gibi mutlu, üzgün, şaşkın gibi duygu ifadelerinin çıkarımı da yapılabilir (Bhardwaj vd., 2015). Duygu analizinde metin, öncelikle alt kelime birimlerine (tokens) ayrılmaktadır. Metinler içerisindeki kelimelerde edat, bağlaç ve zarfların belirlenmesi ve noktalama işaretlerin temizlenmesi duygu analizinin yapılabilmesi için gerekli işlem adımlarındandır. Böylece metinler üzerinde ayrıştırmalar yapılır ve yüksek frekansa sahip alt kelime birimlerinin yanlılık (bias) oluşturmasının önüne geçilerek metinde sadeleştirme sağlanır. Bu sayede metin içinde her bir kelime bir anlamı ifade edecek şekilde listede yalın şekilde barınmış olur. Bu ön işlemler sonrasında çeşitli makine öğrenmesi sınıflandırma yöntemleri kullanılarak duygu analizi gerçekleştirilmektedir (İlhan & Sağaltıcı, 2020).

Bu çalışmada oluşturulan duygu analizi modeline ait akış diyagramı Şekil 3'te gösterilmiştir. Bu aşamada, iletileri ve olumlu-olumsuz anlamda olduğunu ifade eden etiketleri yükleme işlemi gerçekleştirilir (Şekil 3a). Veri ön işleme amacıyla edat, bağlaç, zarf ve gereksiz kelimeler (stop words) gibi cümlede bulunan fakat tek başına anlamlı olmayan terimlerden verinin arındırılması işlemi gerçekleştirilir (Şekil 3b). K-kat çapraz doğrulama (k-fold cross validation) yöntemi uygulanarak eğitim ve test veri setleri belirlenir (Şekil 3c). Kelime hazinesi belirlenir (en sık geçen 10000 kelime belirlenir). Veri kümesindeki metin verisi kullanılarak bir sözlük oluşturulur. Veri setindeki metinler kelime birimlerine ayrılır. Sözlük içerisinde her bir kelimeye benzersiz bir sayı atanır. Bu sayede metin verisi sayısal bir formata dönüştürülür (Şekil 3ç). Veri setindeki kelime birim sayısı hesaplanır. Her iletinin boyutu farklı olduğundan belirli bir ileti boyutu belirlemek için veri setindeki aritmetik ortalama (ort) kelime birim sayısı (num_{tokens})'na iki kat standart sapma (std) eklenerek bir eşik değeri elde edilir. Eşitlik 1 ile belirli bir ileti boyutunu belirlemek için kullanılacak maksimum kelime birimi sayısı ($maks(tokens)$) hesaplanır.

$$maks(tokens) = ort(num_{tokens}) + 2 \times std(num_{tokens}) \quad (1)$$

Kelime birim sayılarının istatistiksel özellikleri kullanılarak bir maksimum sınırlama getirme amaçlanır. Veri setindeki iletilerin kelime birim sayıları belirlenen eşik değerine göre eşitlenir. Bu işlem, bazı iletilerin sonlarına sıfırlar ekleyerek gerçekleştirilir. Bu sayede tüm iletiler aynı boyuta getirilir. Veri seti, sinir ağı modelinde eğitim ve tahmin etme aşamaları için hazır hale getirilir (Şekil 3d).



Şekil 2: İletilerin elde edilmesi amacıyla veri kazıma işlemi için akış diyagramı

2.3 Kapı Yinelemeli Birimler (Gated Recurrent Units, GRU) Derin Ağ Modeli

Bu çalışmada bir yinelemeli sinir ağı yöntemi olan Kapı Yinelemeli Birim Ağları (Gated Recurrent Units, GRU) kullanılmıştır. Yapay sinir ağları başta olmak üzere tüm sinir ağı yöntemleri nöronlara dayanmaktadır. Yapay sinir ağlarında nöronun girdileri farklı ağırlıklarla doğrusal bir şekilde birleştirilir. Bu kombinasyonun sonucunda ise doğrusal olmayan bir aktivasyon birimine aktarılır (Chen vd., 2020). Ağın yüksek bağlanabilirliği hata etkisinin minimum olmasını sağlar. Yinelenen sinir ağları, veri akışlarını analiz edebilen gizli katmanlara sahip özel bir sinir ağı türüdür. Bu ağlar, çıktıların önceki hesaplamalara bağlı olduğu problemleri çözmek için oldukça uygun ve etkilidirler. Williams ve Zipser (1989) tarafından tanıtılan bu yöntem, özellikle doğal dil işleme alanında çeşitli problemlerin üstesinden gelmede başarılı olmuştur. Yinelenen sinir ağları, veri akışlarını dinamik bir şekilde analiz edebilme yetenekleriyle öne çıkarlar. Bu özelliği sayesinde, dilin karmaşıklığını ve sürekli değişen yapısını anlama ve işleme konusunda etkili bir araç haline gelmişlerdir. Bu teknoloji, metin analizi, çeviri, duygu analizi ve daha birçok doğal dil işleme problemine yenilikçi çözümler sunmuştur (Küçük & Arıcı, 2018).

Yinelenen sinir ağlarında öğrenme aşamasında karşılaştığı ağırlıkların yok olması sorunu nedeniyle, bu ağların uzun kısa süreli bellek (Long Sort Term Memory, LSTM) (Hochreiter & Schmidhuber, 1997) ve kapı yinelemeli birimler (Gated Recurrent Unit, GRU) (Cho vd., 2014) gibi çözümleri ortaya çıkmıştır (Küçük & Arıcı, 2018). LSTM birimine benzer şekilde, GRU'nun da birim içinde bilginin akışını modüle eden kapı birimleri vardır; ancak ayrı bir bellek hücresi bulunmaz. Ayrıca LSTM'den farklı olarak sadece iki kapısı vardır. Bunlar, unutulacak geçmiş bilginin miktarına karar vermek için kullanılan sıfırlama kapısı ve atılacak veya eklenecek bilgilere karar veren güncelleme kapısıdır (Sachin vd., 2020). Bu çalışmada model, yinelenen sinir ağındaki gradyanların yok olması probleminden dolayı GRU çözümü ile eğitilmiş ve eğitimde GRU katmanları oluşturulmuştur.

$$h_t^j = (1 - z_t^j)h_{t-1}^j + z_t^j h_{tt}^j \quad (2)$$

$$z_t^j = \sigma(W_z x_t + U_z h_{t-1}^j) \quad (3)$$

$$h_{tt}^j = \tanh(W x_t + U(r_t \odot h_{t-1}^j)) \quad (4)$$

$$r_t^j = \sigma(W_r x_t + U_r h_{t-1}^j) \quad (5)$$

Burada; x_t , giriş vektörünü; h_t^j , önceki h_{t-1}^j aktivasyonu ile aday h_{tt}^j aktivasyonu arasında t anındaki doğrusal enterpolasyonu (çıkıtı vektörünü); z_t^j , güncelleme geçidi vektörünü; U , W_z , W_r , W , ağırlık matrislerini; σ , aktivasyon fonksiyonunu; r_t , sıfırlama geçidi vektörünü; \odot , vektörler arası elementer çarpımı ifade eder. Bu eşitlikler kullanılarak, modelin geçmiş bilgileri hatırlaması, anlık bilgiyi işlemesi ve önemli bilgileri vurgulaması sağlanır (Sachin vd., 2020).

Bu aşamada, model oluşturmak amacıyla modelin ilk katmanına bir gömme katmanı (embedding layer) eklenir. Bu katman, metin verilerini temsili vektörlere dönüştürmek için kullanılır. Üç adet GRU katmanı eklenir. İkili sınıflandırmalı bir sonuç almak için yoğun katman içinde sigmoid aktivasyon fonksiyonu kullanılır (Şekil 3e). Modelin daha iyi öğrenmesi için büyük veri setleri ve karmaşık modellerle çalışırken etkili olan "Adam" optimizasyonu kullanılır. Modelin hazır hale getirilmesi için kayıp fonksiyonu olarak ikili sınıflandırma görevi seçilir. Bu fonksiyon, modelin tahminlerinin referans etiketlerden ne kadar uzak olduğunu ölçer (Şekil 3f). Veri seti, k-kat çapraz doğrulama yöntemi kullanılarak 5 katmana bölünür. Her bir iterasyon için eğitim ve test kümeleri oluşturulur. Model veri üzerinde eğitilir (Şekil 3g). Model, test verileri üzerinde tahminler yapar (Şekil 3ğ). Tahmin olasılıklarında eğer bir tahmin olasılığı 0.5'ten büyükse olumlu (1) sınıfına atama, küçükse

olumsuz (0) sınıfına atama işlemi gerçekleştirilir (Şekil 3h).

2.4 Sınıflandırmada Test Doğruluğunun Değerlendirilmesi

Sınıflandırma performansı çeşitli metriklerle değerlendirilebilir. Sınıflandırma modellerinin test verileri üzerindeki performansını değerlendirmek için hata matrisi kullanılır. Hata matrisi tahmin sonuçlarını gösterir. Hata matrisi içerisindeki Doğru Pozitif (DP) (True Positive, TP), Doğru Negatif (DN) (True Negative, TN), Yanlış Pozitif (YP) (False Positive, FP) ve Yanlış Negatif (YN) (False Negative, FN), modelin tahminlerinin doğruluğunu belirlemede kullanılır. Bu değerlendirmeler, test edilen modelin, referans (ground truth) veriler üzerindeki başarısını gösterir. N, test edilen örneklerin toplam sayısıdır. DP, modelin doğru bir şekilde pozitif olarak sınıflandırdığı durumlardır. DN, modelin doğru bir şekilde negatif olarak sınıflandırdığı durumlardır. YP, modelin yanlış bir şekilde pozitif olarak sınıflandırdığı ve YN, modelin yanlış bir şekilde negatif olarak sınıflandırdığı durumlardır (Markoulidakis vd., 2021). Değerlendirmede doğruluk, kesinlik, duyarlılık ve F1 Skor gibi metrikler kullanılmıştır. Doğruluk ölçütü, doğru tahminlerin toplam test sayısına oranıdır ve başarıyı yansıtır.

$$\text{Doğruluk (Accuracy)} = \frac{DP+DN}{N} \quad (6)$$

Kesinlik (Precision) ölçütü, pozitif olarak sınıflandırılmış örnekleri değerlendirir. Model ne kadar yüksek bir kesinlikle çalışıyorsa, pozitif olarak sınıflandırılan örneklerin gerçekten pozitif olma olasılığı o kadar yüksektir. Kesinlik, doğru olarak sınıflandırılmış pozitif örneklerin, tahmin edilen toplam pozitif örneklere olan oranını ifade eder.

$$\text{Kesinlik (Precision)} = \frac{DP}{DP+YP} \quad (7)$$

Duyarlılık (Recall) ölçütü, pozitif olarak sınıflandırılmış örnekleri değerlendirir. Bu ölçü, doğru olarak sınıflandırılmış pozitif örneklerin, referans verisindeki toplam pozitif örneklere olan oranını ifade eder.

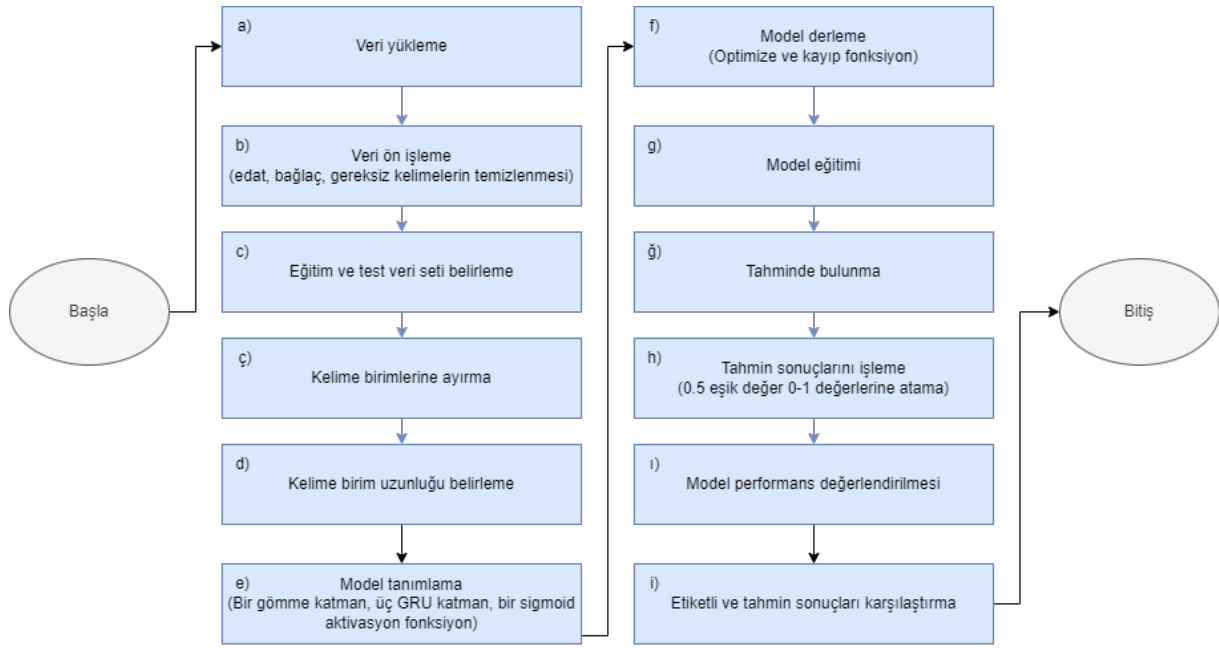
$$\text{Duyarlılık (Recall)} = \frac{DP}{DP+YN} \quad (8)$$

F1 Skor (F1 Score), kesinlik ve duyarlılık ölçütlerinin birlikte hesaplanmasıyla elde edilir. Bu ölçüt, kesinlik ve duyarlılık değerlerinin ağırlıklı harmonik ortalamasının alınmasıyla belirlenir. Yüksek F1 Skor, sınıflandırma performansının kalitesini ifade eder (Gündüz, 2013).

$$\text{F1 Skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (9)$$

Bu çalışmada, duygu analizi modeli üzerinde eğitim ve test veri setinin belirlenmesi için k-kat çapraz doğrulama yöntemi uygulanmıştır. Çapraz doğrulama yöntemi, bir öğrenme setini eğitmek ve değerlendirmek için kullanılan bir yöntemdir. Öğrenme seti, yaklaşık olarak eşit büyüklükte k adet alt kümeye bölünür. Her bir alt küme sırasıyla doğrulama seti olarak kullanılırken, geriye kalanlar eğitim seti olarak kullanılır. Model k defa eğitilir ve her seferinde bir farklı alt küme doğrulama için ayrılır. Sonuçların ortalaması alınarak çapraz doğrulama performansı elde edilir (Berrar, 2019).

Bu aşamada, model performans değerlendirilmesi işlemi gerçekleştirilir. Performansın değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve F1 Skor sonuçları hesaplama işlemi gerçekleştirilir (Şekil 3i). Etiketli veri ve model tahmin sonuçları il bazında karşılaştırılır (Şekil 3i).



Şekil 3: Duygu analizine ait kod akış diyagramı

2.5 Sıcak Nokta Analizi

Sıcak nokta (hot spot) analizi (Getis-Ord G_i^*), her bir özneteliğin çevresindeki diğer özneteliklerle olan ilişkisini değerlendirerek mekânsal kümelenme desenlerini araştırır. Bir noktanın istatistiksel olarak anlamlı bir sıcak nokta olabilmesi için, bu noktanın yüksek bir değere sahip olması gerektiği gibi, aynı zamanda çevresindeki diğer noktaların da yüksek değerlere sahip olması gerekir. Elde edilen z-istatistiği ve p-değeri, yüksek veya düşük değerlere sahip nesnelerin mekânsal olarak kümelenmesini gösterir (URL-5). Eşitlik 10’da verilen G_i^* yerel istatistiği z-istatistiği değeridir. Örneklemdaki tüm noktalar için G_i^* hesaplanarak, çalışma alanındaki (belli anlamlılık düzeylerinde) sıcak ve soğuk noktalar belirlenir. Pozitif ve belli bir anlamlılık düzeyinde kritik z değerinden büyük G_i^* değerlerine sahip noktalar sıcak nokta; negatif ve belli bir anlamlılık düzeyinde kritik z değerinden küçük G_i^* değerlerine sahip noktalar ise soğuk noktaları oluşturur. Bunun dışında kalan durumlar ise rastlantısal dağılımı gösterir (Çubukçu, 2015).

$$G_i^* = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\frac{n \sum_{j=1}^n w_{i,j}^2 - (\sum_{j=1}^n w_{i,j})^2}{n-1}}} \quad (10)$$

$$\bar{X} = \frac{\sum_{j=1}^n x_j}{n} \quad (11)$$

$$S = \sqrt{\frac{\sum_{j=1}^n x_j^2}{n} - (\bar{X})^2} \quad (12)$$

Burada; n, örneklemdaki nokta sayısını; x_j , j noktasına ait değişken değerini; $w_{i,j}$, i noktası ve j noktası arasındaki yakınlık ilişkisini veren mekânsal ağırlık değerini; \bar{X} , değişkene ait ortalama değeri belirtir.

3. Bulgular ve Tartışma

Veri kümesi, X platformundan 685 adet iletinin kazıma işlemi ile elde edilmiştir. Veri kazıma aşamasında “6 Şubat 2023” anahtar kelimesini içeren ve Adana, Adıyaman, Batman, Bingöl, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş,

Kayseri, Kilis, Malatya, Mardin, Niğde, Osmaniye, Şanlıurfa ve Tunceli illerinden gönderilen iletilerin elde edilmesi sağlanmıştır. BeautifulSoup ve Selenium kütüphanesi ile kazıma işlemi yapıldıktan sonra Pandas kütüphanesi ile bir veri çerçevesi oluşturulmuştur.

İletilerden oluşan veri setinin kalitesinin iyileştirilmesi adına, elde edilen verilerin kontrolü gönderilerin özelliklerine göre yapılmıştır. Tablo 1’de bu çalışmada gönderilere ait özellikler verilmiştir. Çalışmada kullanılan iletiler; konusu, beğeni sayısı, gönderi sahibinin birden fazla gönderisinden sadece birinin alınması ve gönderi tarih aralıkları gibi özelliklerine göre filtrelenerek seçilmiştir.

Tablo 1: Gönderilere ait özellikler ve açıklamalar

Gönderiye ait özellikler	Açıklama
Gönderi konusu	6 Şubat 2023 depremleri hakkında bilgi ve görüş içermesi
Gönderi beğeni sayısı	Gönderilerin genel kullanıcılar arasında desteklenme durumu
Gönderi sahibi	Aynı gönderinin aynı kişiden birden fazla atılması
Gönderi tarihi	Haziran 2023 – Eylül 2023

Ön işlemde geçen veri seti ikili olarak olumlu veya olumsuz düşünce belirtmesi durumuna göre etiketlenmiştir. Duygu analizi amacıyla kapı yinelemeli birimler derin öğrenme ağları ile veriler sınıflandırılmıştır. Veriler sınıflandırılırken ilk olarak sinir ağına girdi olarak bir ileti eklenmiştir ve eklenen bu ileti, kelimelerin vektörlerinden oluşan kelime birimleriyle (tokenlerle) temsil edilmektedir. Gömme (embedding) katmanı, ileti içindeki kelimelere karşılık gelen vektörleri içermektedir. Bu vektörler, bir sonraki GRU katmanına çıkış olarak aktarılmaktadır. Bu çalışmada, veri sayısının az olmasından dolayı 3 adet GRU katmanı oluşturulmuştur. Kelime vektörleri, üç GRU katmanında işlenmiştir ve en son çıktı katmanındaki tek bir nörona iletilmiştir. Bu nöron, değerleri tek bir sayıya dönüştürerek sigmoid aktivasyon fonksiyonundan geçirmiştir ve 0 ile 1 arasında bir değer döndürmüştür. Bu değer, modelin çalışılan ileti (X gönderisi) hakkındaki tahminidir. Eğer sonuç 1’e yakınsa, model o iletiyi olumlu olarak değerlendirir; 0’a yakınsa, o gönderiyi olumsuz olarak değerlendirir (Chen vd., 2020).

Duygu analizinde kullanılan sınıflandırmada veriye k-kat çapraz doğrulama uygulanmış ve performansın değerlendirme sonuçları belirlenmiştir. Model, verilen veri setini k-kat çapraz doğrulama yönteminden geçirerek eğitimi tamamlamıştır. Bu çalışmada k = 5 alınmıştır. Burada amaç modelin eğitimini doğru bir şekilde tamamlamış olduğunu test etmektir. Eğitim sonucunda test verisinin doğruluğu Bölüm 2.4’te belirtilen metriklere göre belirlenmiştir. Tablo 2 ve Tablo 3’te derin öğrenme ağında eğitim sonucu modelin performansını değerlendiren test verisinin tahmini hakkında metrik sonuçları genel olarak verilmiştir. Sonuçlara göre, referans veride olumsuz (0) olarak etiketli iken modelin de olumsuz (0) olarak tahmin ettiği ileti sayısı 475 olarak bulunmuştur. Referans veride olumsuz (0) olarak etiketli iken modelin olumlu (1) olarak tahmin ettiği bir sonuç bulunmamaktadır. Referans veride olumlu (1) olarak etiketli iken modelin olumsuz (0) olarak tahmin ettiği ileti sayısı 90 olarak bulunmuştur. Referans veride olumlu (1) olarak etiketli iken modelin de olumlu (1) olarak tahmin ettiği ileti sayısı 120 olarak bulunmuştur. Tablo 2’de hata matrisi olumsuz (0) sınıfını doğru bir şekilde tahmin etme yeteneğinin, olumlu (1) sınıfını tahmin etme yeteneğinden daha yüksek olduğu görülmektedir. Bu durum, kesinlik değerinin yüksek (1.00); duyarlılık değerinin ise düşük (0.57) olmasına yol açmıştır. Bir başka deyişle, referans veride (gerçekte) olumsuz olan iletilerin tümü doğru sınıflandırılmasına rağmen, gerçekte olumlu olan iletilerin %57’si doğru olarak sınıflandırılmıştır. Olumsuz (0) olarak etiketli ileti sınıfının daha net ifadeler ve kısa cümleler içermesi (korkuyoruz, uyuyamıyoruz vb.) modelin bu sınıfı daha iyi öğrenmesine sebep olmuştur. Ancak, olumlu (1) olarak etiketli ileti sınıfının daha karışık ifadeler (örneğin, “üzgünüz ve yanınızdayız” gibi hem olumsuz hem de olumlu duygu durumlarını bir arada bulunduran) ve daha uzun cümleler

içermesi, modelin bu sınıfı daha zor öğrenmesine neden olmuştur. Eğitimini tamamlayan modele test veri seti olarak Adana, Adıyaman, Batman, Bingöl, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş, Kayseri, Kilis, Malatya, Mardin, Niğde, Osmaniye, Şanlıurfa ve Tunceli konumlarından elde edilen etiketli X iletileri gönderilmiştir. Derin öğrenme ağının Adıyaman, Hatay ve Kahramanmaraş illeri üzerindeki tahmin doğruluk sonuçları Tablo 4’te gösterilmiştir. Adıyaman ili için ortalama test tahmin doğruluğu %82, Hatay için %70 ve Kahramanmaraş ili için ise %90 olduğu tespit edilmiştir. İl bazında ortalama test doğruluklarının birbirine yakın olduğu ve %70-%90 arasında değiştiği görülmüştür. Test doğruluğunun düşük olduğu illerde nötr olarak da değerlendirilebilecek yorumların (olumlu ya da olumsuz ifadelerin daha belirsiz) olması nedeniyle eğitim modelinin daha düşük performans ile çalıştığı gözlemlenmiştir.

Tablo 2: Derin öğrenme ağında test sonucu model performansını değerlendiren hata matrisi

		Tahmin		
		Olumlu (Pozitif)	Olumsuz (Negatif)	Toplam
Referans (Gerçek)	Olumlu (Pozitif)	120 (DP)	90 (YN)	210
	Olumsuz (Negatif)	0 (YP)	475 (DN)	475
	Toplam	120	565	685

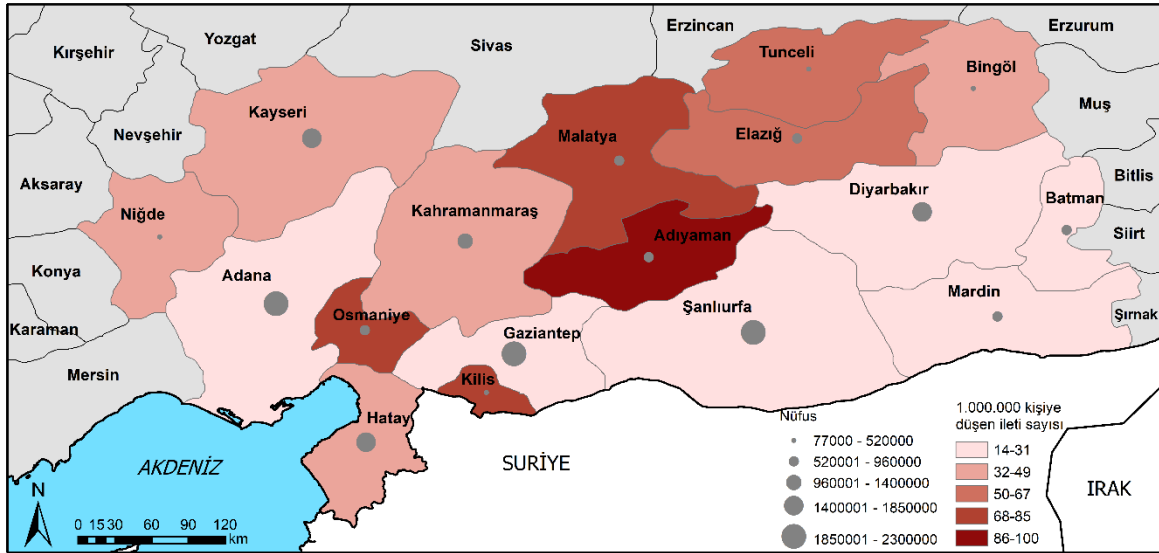
Tablo 3: Derin öğrenme ağında test sonucu model performansını değerlendiren genel metrik sonuçları

Metrik	Genel sonuç
Doğruluk	0.87
F1 Skor	0.73
Duyarlılık	0.57
Kesinlik	1.00

Tablo 4: Derin öğrenme ağının Adıyaman, Hatay ve Kahramanmaraş veri seti üzerinde tahmin performansını değerlendiren metrik sonuçları

Metrik	Adıyaman	Hatay	Kahramanmaraş
Doğruluk	0.82	0.70	0.90
F1 Skor	0.74	0.58	0.87
Duyarlılık	0.82	0.70	0.90
Kesinlik	0.67	0.49	0.83

Duygu analizi modeli sonucunda elde edilen verilerin ileti sayıları, gönderilerin konum bilgileri ve Türkiye İstatistik Kurumu (TÜİK) 2023 illere göre elde edilen nüfus sayıları CBS ortamına (ArcGIS Pro kullanılarak) aktarılmıştır (URL-7). Öncelikle ileti sayılarının nüfusa göre normalize edilmesi işlemi gerçekleştirilmiştir. 6 Şubat 2023 deprem bölgeleri için normalize edilmiş olan iletilerin koroplet (renk tonlu) haritası Şekil 4’te verilmiştir. Ayrıca haritada ikinci bir bilgi olarak 6 Şubat 2023 depreminden etkilenen illerin nüfus bilgisi orantılı işaret haritası olarak sunulmuştur. İletiler Haziran-Eylül 2023 zaman dilimini kapsamaktadır. Şehirlerin nüfus sayılarına oranla 6 Şubat 2023 anahtar kelimeli iletilerin en az paylaşımının Şanlıurfa, Diyarbakır ve Mardin illerinden gönderildiği ortaya çıkmıştır. Nüfusun daha az olduğu Kilis’te ise nüfusa oranla daha fazla iletinin paylaşıldığı görülmektedir.

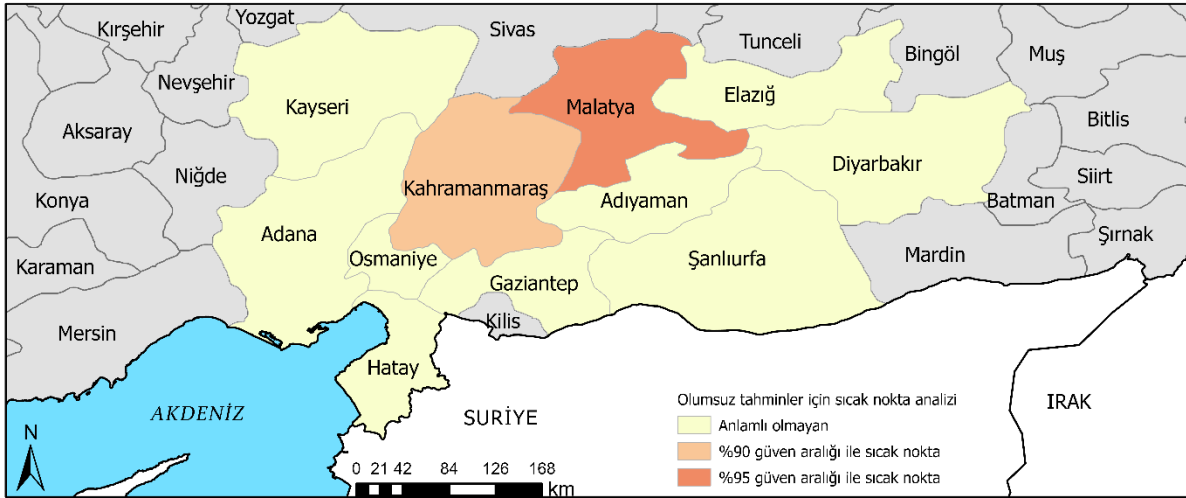


Şekil 4: 6 Şubat 2023 depreminden etkilenen illerin nüfusa oranla X uygulamasındaki depremle ilgili ileti sayıları

Referans olumlu-olumsuz ve tahmin olumlu-olumsuz ileti sayıları ait olduğu ilin nüfusuna göre normalize edilmiştir. İllere ait sıcak nokta analizinde kullanılacak olan olumlu-olumsuz ileti sayıları için 17 ilin (Adana, Adıyaman, Batman, Bingöl, Diyarbakır, Elâziğ, Gaziantep, Hatay, Kahramanmaraş, Kayseri, Kilis, Malatya, Mardin, Niğde, Osmaniye, Şanlıurfa ve Tunceli) ileti sayılarının aritmetik ortalaması alınmıştır. Aritmetik ortalama sonucuna göre bir eşik değeri belirlenmiştir. Batman, Bingöl, Kilis, Mardin, Niğde ve Tunceli illerine ait ileti sayılarının ortalama ileti sayısından düşük olmasının verebileceği yanlışlık nedeni ile 6 il sıcak nokta analizinden muaf tutulmuştur. Elde edilen nüfusa göre normalize edilmiş referans ve tahmin olumlu-olumsuz ileti sayıları üzerinden Adana, Adıyaman, Diyarbakır, Elâziğ, Gaziantep, Hatay, Kahramanmaraş, Kayseri, Malatya, Osmaniye ve Şanlıurfa illeri için sabit mesafe bant (fixed distance band) ilişkisi ile sıcak nokta analizi yapılmıştır. Referans ve tahmin olumlu-olumsuz iletilerin sıcak nokta analiz sonucuna göre her iki ileti grubunun da aynı anlamlılık düzeylerinde ($\alpha=0.10$; $\alpha=0.05$; $\alpha=0.01$) aynı kümelenme sonucunu verdiği gözlemlenmiştir. İllere göre duygu analizi modelinin olumsuz tahmin ileti sayılarının sıcak nokta analizi sonucu Şekil 5'te verilmiştir. Şekil 5'te Malatya için 0.05 anlamlılık düzeyinde, Kahramanmaraş için 0.10 anlamlılık düzeyinde diğer illere kıyasla olumsuz iletilerin kümelenmiş (sıcak nokta) olduğu öne çıkmaktadır. Referans ve tahmin ileti grupları üzerindeki sıcak nokta analizlerinin sonucunda aynı anlamlılık düzeyinde sonuç vermesi referans ve duygu analizi modelinin verdiği tahmin sonucu ileti sayılarının arasında anlamlı bir fark olmadığını ortaya çıkarmaktadır. Bu çalışmada, sırasıyla Malatya ve Kahramanmaraş illerinde nüfusa oranla olumsuz ileti sayılarının istatistiki olarak yüksek değer gösterdiği anlaşılmaktadır. Diğer iller nüfusa oranla olumsuz ileti sayısına göre istatistiksel olarak rastlantısal dağılım göstermektedir. Tablo 5'te görülen il bazında ileti sayılarının artması, sıcak nokta analizinde kullanılan z-testinin daha güçlü olmasını sağlayacaktır. Ayrıca, psikososyal destek planlamasında, kitlenin duygu durumu ile birlikte ihtiyaç ve taleplerin mekânsal analizleri de dikkate alınarak planlamaların yapılması gerekmektedir. Bu bağlamda, bu çalışma, psikososyal destek kapsamına alınacak öncelikli illerin belirlenmesine dair bir tespit yapmamakta; doğal dil işleme ve derin öğrenme ile yapılan duygu analizlerinin ve duygu durumları kullanılarak yapılan sıcak nokta analizlerinin CBS tabanlı psikososyal destek planlaması çalışmalarına katkı sağlayabileceğini vurgulamaktadır.

Tablo 5: İl bazında ileti sayıları

İl	İleti Sayısı
Tunceli	4
Kilis	11
Mardin	12
Niğde	12
Bingöl	14
Batman	15
Elâzığ	36
Osmaniye	46
Diyarbakır	49
Hatay	54
Gaziantep	58
Şanlıurfa	58
Adana	59
Kahramanmaraş	59
Kayseri	65
Adıyaman	66
Malatya	67



Şekil 5: 6 Şubat 2023 depreminden etkilen illerden edinilen olumsuz ileti sayıları ile ilgili sıcak nokta analizi (referans ve tahmin haritaları ayrıdır)

Literatürde X platformu üzerinden belli ilgi noktalarından elde edilen veya toplumsal (ünlü birinin bir şehri ziyaret etmesi), siyasal (darbe girişimleri, ülkede yaşanan protestolar vs.) ve doğal olaylar (deprem, sel, yoğun yağış vs.) ile ilgili konular hakkındaki iletilerden yapılan duygu analizi çalışmaları oldukça yaygındır. Bu çalışmanın literatürdeki çalışmalardan farkı, 6 Şubat 2023 depremleri ile ilgili insanların duygu durumlarını ve değişimlerini analiz edilmesidir. Bu çalışmada kullanılan veri kazıma ve duygu analizi metodolojisi özgün olarak kurgulanmış ve diğer afet konularına adapte edilebilir esnek bir algoritma ile ortaya çıkmıştır. Olumlu ve olumsuz olmak üzere veriler iki sınıf olacak şekilde etiketlenmiştir. Ancak, duygu durumlarının (korkma, üzülmeye, şaşkınlık, mutluluk gibi) çeşitlilik göstermesi nedeniyle verilerin daha fazla sınıfa ayrılarak etiketlenmesi duygu durumlarının daha detaylı tanımlanmasını sağlayabilir. Bu nedenle, modelin eğitiminde kullanılacak

etiketlerin daha fazla olması modelin tahmin doğruluğunu geliştirebilir. Kullanılan veri kaynağının sosyal medya olması ve kitle kaynaklı toplanan verilerin çelişkili veya anlaşılması güç metinleri içerebilmesi duygu analizinde kullanılan makine öğrenimi yöntemlerinin performansını olumsuz yönde etkileyen zorluklardan biridir. Bu çalışmada gözlemlendiği gibi duygu durumu belirsiz ifadeler sınıflandırıcının performansını düşürebilmektedir. Ayrıca sosyal medya verilerinin CBS ortamında analiz edilmesi ile ilgili bir diğer zorluk olarak kullanıcıların konumu kapalı bir biçimde paylaştıkları iletilerin CBS ortamına dahil edilememesi olarak değerlendirilebilir.

4. Sonuç ve Öneriler

Bu çalışmada, X platformu üzerinden Kahramanmaraş depremlerine ait Haziran-Eylül 2023 tarihleri arasındaki 685 adet gönderiye erişilmiştir. Veri kazıma kütüphanelerinden BeautifulSoup ve Selenium kullanılarak otomatik bir şekilde istenen sayıda gönderinin elde edilmesi işlemi gerçekleştirilen bir Python kodu hazırlanmıştır. Hazırlanan derin öğrenme eğitim modeli sayesinde yaşanmış veya yaşanabilecek depremler sonrasında anlık olarak istenilen platform üzerinden veri kazıma ve duygu analizi yapılabilir hale getirilmiştir.

Elde edilen veriler olumlu ve olumsuz anlamlarını taşıyan 1 ve 0 etiketlerine sahip veri seti haline getirilmiştir. Verileri doğal dil ön işleme tekniklerinden geçiren ve duygu analizini yapan hazır bir model geliştirilmiştir. Model, verilen veri setinin eğitimini ortalama %87 doğrulukla tamamlamıştır. Model eğitimini tamamlayıp veri seti üzerinde tahminlerini gerçekleştirdiğinde ise verinin %82.5'ini olumsuz etiketli, %17.5'ini olumlu etiketli olarak sınıflandırmıştır. Veri setinde olumlu etikete sahip olan fakat modelin tahmin sonucunda olumsuz etiket sınıfına eklenen gönderiler incelenmiştir. Bu gönderilerin modelin karıştırabileceği duygu durumu belirsiz ifadeler içerdiği fark edilmiştir. Bu ifadeler örnek olarak bir cümle içerisinde depremin yıkıcı etkilerinden bahsedilirken diğer yandan deprem sonrası yardımlaşma mesajı ile iletilerini bitiren uzun gönderiler verilebilir.

Bu çalışmada, Kahramanmaraş depremleri ile ilgili sosyal medya verilerinin doğal dil işleme ve kapı yinelemeli birimler derin öğrenme modeli kullanılarak duygu analizinin gerçekleştirilebileceği gösterilmiştir. Herhangi bir deprem sonrasında duygu analizi yapabilen bu model sayesinde, afet hakkında duygu analizi güncel olarak gerçekleştirilebilecektir. Ayrıca tahmin verilerinden sıcak nokta analizi ile iletiler arasındaki kümelenme örüntülerinin istatistiki olarak tespit edilebileceği ve bu kümelerin psikososyal planlama aşamasında fikir verebileceği görülmektedir. Gelecek çalışmalarda, sosyal medya üzerinden paylaşılan yeni iletiler de mevcut giriş veri setine eklenerek daha geniş bir sözlük kullanılarak derin öğrenme modelinin eğitimi geliştirilebilir ve sonuçlar iyileştirilebilir. Ayrıca, duygu analizinde daha fazla etiket üretmek (korkma, üzülmeye, şaşkınlık, mutluluk gibi) farklı derin öğrenme eğitim modelleri test edilebilir. Duygu analizinin sonuçları CBS ortamına aktararak duygu durum değişimleri mekân-zaman kapsamında analiz edilebilir.

Yazar Katkısı

Dilan Gözdem Dolu: Literatür taraması, Veri toplama, Analiz ve yorumlama, Yazım. **Alper Şen:** Fikir, Tasarım, Makale değerlendirme, Denetleme, Yazım.

Çıkar Çatışması Beyanı

Yazarlar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Adalı, E. (2012). Doğal dil işleme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(2).
- Albayrak, M., Topal, K., & Altıntaş, V. (2017). Sosyal medya üzerinde veri analizi: Twitter. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 22(Kayfor 15 Özel Sayısı), 1991-1998.
- Berrar, D. (2019). Cross-validation. *Encyclopedia of Bioinformatics and Computational Biology*. 1, 542-545.
- Bhardwaj, A., Narayan, Y., & Dutta, M. (2015). Sentiment Analysis for Indian Stock Market Prediction Using Sensex and Nifty. *Procedia Computer Science*, 70, 85-91.
- Camacho, K., Portelli, R., Shortridge, A., & Takahashi, B. (2021). Sentiment Mapping: Point Pattern Analysis of Sentiment Classified Twitter Data. *Cartography and Geographic Information Science*, 48(3), 241-257.
- Chen, L. C., Lee, C. M., & Chen, M. Y. (2020). Exploration of Social Media for Sentiment Analysis Using Deep Learning. *Soft Computing*, 24, 8187-8197.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation. *arXiv preprint arXiv*, 1406-1078.
- Clarke, K.C. (1997). *Getting started with geographic information systems* (25-30). New Jersey: Prentice Hall.
- Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K., & Kuksa, P. (2011). Natural Language Processing (Almost) from Scratch. *Journal of Machine Learning Research*, 12, 2493-2537.
- Çubukçu, K.M. (2015). *Planlamada ve Coğrafyada Temel İstatistik ve Mekânsal İstatistik*. Ankara: Nobel Akademik Yayıncılık.
- Feng, Y., Huang, X., & Sester, M. (2022). Extraction and Analysis of Natural Disaster Related Vgi from Social Media: Review, Opportunities and Challenges. *International Journal of Geographical Information Science*, 36(7), 1275-1316.
- Gulnerman, A. G., & Karaman, H. (2020). Sosyal Medyanın Gönüllü Coğrafi Veri Olarak Kullanımı ve Sosyal Medya Verilerinden Coğrafya Sözlüğü Üretimi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 20(2), 276-286.
- Gulnerman, A. G., Karaman, H., Pekaslan, D., & Bilgi, S. (2020a). Citizens' Spatial Footprint on Twitter-Anomaly, Trend and Bias Investigation in Istanbul. *ISPRS International Journal of Geo-Information*, 9(4), 222.
- Gulnerman, A. G., Karaman, H., & Basiri, A. (2020b). New age of crisis management with social media. *Open Source Geospatial Science for Urban Studies: The Value of Open Geospatial Data* (131-160). Berlin:Springer.
- Gündüz, H. (2013). Borsa İstanbul (BIST) 100 Endeksi Yönünün Ekonomi Haberleri ile Tahmin Edilmesi (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Häberle, M., Werner, M., & Zhu, X. X. (2019). Building type classification from social media texts via geo-spatial textmining. *2019 IEEE International Geoscience And Remote Sensing Symposium* (10047-10050). Yokohama, Japonya.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- İlhan, N., & Sağaltıcı, D. (2020). Twitter'da Duygu Analizi. *Harran Üniversitesi Mühendislik Dergisi*, 5(2), 146-156.
- Kaya, A. (2021). Bir Araştırma Kaynağı Olarak Arşivlenen Sosyal Medya Verilerinin Kullanımı. *Bilgi ve Belge Araştırmaları*, (16), 49-79.
- Kılınç, M., Aydın, C., & Tarhan, Ç. (2022). Türkiye'de Sosyal ve Dijital Girişimcilik: Veri Kazıma Teknikleriyle Kitle Fonlaması Platformlarının İçerik Analizi. *Acta Infologica*, 6(1), 83-97.
- Koç, M., & Yalçın, S. (2023). Afetlerde Krize Müdahale: Kahramanmaraş Depremi'nde Aile ve Sosyal Hizmetler Bakanlığı'nın Çalışmaları. *Uluslararası Sosyal Hizmet Araştırmaları Dergisi*, 3(2), 93-105.
- Küçük, D., & Arıcı, N. (2018). Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2(2), 76-86.
- Markoulidakis, I., Kopsiaftis, G., Rallis, I., & Georgoulas, I. (2021). Multi-class confusion matrix reduction method and its application on net promoter score classification problem. *In The 14th Pervasive Technologies Related to Assistive Environments Conference* (412-419). Korfu, Yunanistan.
- Neal, D.M., (1997). Reconsidering the Phases of Disasters. *International Journal of Mass Emergencies and Disasters*, 15 (2), 239-264.
- Özgür E. M. & Aydın, O. (2011). Türkiye'de Evlilik Göçünün Mekânsal Veri Analizi Teknikleriyle Değerlendirilmesi. *Coğrafi Bilimler Dergisi*, 9(1), 29-40.
- Sachin, S., Tripathi, A., Mahajan, N., Aggarwal, S., & Nagrath, P. (2020). Sentiment analysis using gated recurrent neural networks. *SN Computer Science*, 1, 1-13.

- Şeker, S. E. (2015). Metin Madenciliği (Text Mining). *YBS Ansiklopedi*, 2(3), 30-32.
- Wang, R. Q., Mao, H., Wang, Y., Rae, C., & Shaw, W. (2018). Hyper-Resolution Monitoring of Urban Flooding with Social Media and Crowdsourcing Data. *Computers & Geosciences*, 111, 139-147.
- Williams, R. J., & Zipser, D. (1989). A Learning Algorithm for Continually Running Fully Recurrent Neural Networks. *Neural Computation*, 1(2), 270-280.
- Zhao, B. (2017). Web Scraping. *Encyclopedia of Big Data*. Cham: Springer.
- Zhou, X., & Xu, C. (2017). Tracing the Spatial-Temporal Evolution of Events Based on Social Media Data. *ISPRS International Journal of Geo-Information*, 6(3), 88.
- URL-1: Afet ve Acil Durum Müdahale Hizmetleri Yönetmeliği (2013), Resmî Gazete. <https://www.resmigazete.gov.tr/eskiler/2013/12/20131218-13-1.pdf> (Erişim Tarihi: 02 Ocak 2024).
- URL-2: AFAD Türkiye Afet Müdahale Eylem Planı (TAMP) (2014). https://www.afad.gov.tr/kurumlar/afad.gov.tr/e_Kutuphane/Planlar/TAMP.pdf (Erişim Tarihi: 02 Ocak 2024).
- URL-3: Aile ve Toplum Hizmetleri Genel Müdürlüğü (2023), Psikososyal Destek Rehberi. <https://www.aile.gov.tr/uploads/athgm/uploads/pages/goc-afet-ve-acil-durumlarda-psikososyal-destek/psi-kososyal-destek-nedi-r.pdf> (Erişim Tarihi: 02 Ocak 2024).
- URL-4: AFAD (2023), Basın Bülteni. 36. <https://www.afad.gov.tr/kahramanmarasta-meydana-gelen-depremler-hk-36> (Erişim Tarihi: 02 Ocak 2024).
- URL-5: Esri (2024), How Hot Spot Analysis (Getis-Ord Gi*) Works. <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-statistics/h-how-hot-spot-analysis-getis-ord-gi-spatial-stati.htm> (Erişim Tarihi: 13 Şubat 2024).
- URL-6: Python (2021) Real Python. Beautiful Soup: Build a Web Scraper With Python – Real Python (Erişim Tarihi: 02 Ocak 2024).
- URL-7: Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=Nufus-ve-Demografi-109> (Erişim Tarihi: 02 Ocak 2024).

Trimble RTX servisi kullanılarak uydu kombinasyonlarının hız kestirimine etkisinin incelenmesi

Deniz Öz Demir^{1*} 

¹Yıldız Teknik Üniversitesi, Davutpaşa Kampüsü, İnşaat Fakültesi, Harita Mühendisliği Bölümü, Esenler, İstanbul, Türkiye.

Öz: Yer kabuğunun sürekli hareket halinde olması GNSS istasyonlarının da konumlarının değişmesi anlamına gelmektedir. Bu nedenle GNSS istasyonlarının koordinatları ile bu koordinatlara bağlı olarak hesaplanan parametrelerin doğrulukları önem kazanmaktadır. Bu çalışmada IGS (International GNSS Service) tarafından oluşturulan MGEX (Multi-GNSS Experiment) ağına ait seçilen iki noktada internet tabanlı Trimble RTX servisi kullanılmıştır. 24 saatlik veriler 4'er, 6'şar, 8'er ve 12'şer saatlik gözlem sürelerine bölünerek GPS (G), GPS+GLONASS (GR) ve GPS+GLONASS+Galileo (GRE) uydu kombinasyonlarına göre değerlendirilmiştir. Farklı uydu kombinasyonlarına ve farklı ölçüm sürelerine göre 5 yıllık GNSS verileri yardımıyla elde edilen koordinatlar kullanılarak en küçük kareler kestirim yöntemine göre hız bileşenleri kestirilmiştir. Her kombinasyonun kendi içinde tutarlı sonuçlar verdiği görülmüştür. Ancak, GPS verisinden elde edilen sonuçların doğru olarak kabul edilip diğer kombinasyonlarla karşılaştırıldığında tek başına GLONASS'ın değil GLONASS ve Galileo'nun birlikte eklenmesiyle doğruluğun arttığı söylenebilmektedir.

Anahtar Sözcükler: GNSS, Trimble RTX, Hız kestirimi, Doğruluk

Investigation of the effect of satellite combinations on velocity estimation by using Trimble RTX service

Abstract: The earth's crust is in motion means that GNSS stations coordinates are also change. For this reason, the coordinates of GNSS stations and accuracies of the parameters which calculated based on these coordinates become important. In this study, online GNSS processing service Trimble RTX was used for two stations belongs to the MGEX (Multi-GNSS Experiment) network set up by IGS (International GNSS Service). 24-hour data is divided into 4, 6, 8 and 12 hour epochs and processed for GPS (G), GPS+GLONASS (GR) and GPS+GLONASS+Galileo (GRE) satellite combinations. Velocity components are estimated according to the least square estimation method using the coordinates obtained from 5-year of GNSS data by using different satellite combinations and different session durations. It has been observed that each of the combinations are consistent results in itself. However, when the results obtained from GPS data are accepted as true values and these are compared to other combinations, it can be said that the accuracy increased with not only GLONASS but also GLONASS and Galileo together.

Keywords: GNSS, Trimble RTX, Velocity estimation, Accuracy

1. Giriş

Jeodezide nokta konumunun belirlenmesine bağlı olarak çok geniş bir uygulama alanı bulunmaktadır (yer değiştirme büyüklüklerinin belirlenmesi, deprem öncesi ve sonrası deformasyon büyüklerinin belirlenmesi, nokta hız ve gerinim alanlarının belirlenmesi vb.). Teknoloji geliştikçe nokta konumlarının belirlenmesinde birçok yöntem geliştirilmiştir. GPS'in kullanılmaya başlanması ile birlikte yersel ölçme yöntemlerine zaman ve maliyet açısından alternatif yöntemler ortaya çıkmıştır. Bu yöntemlerle birlikte hangi yöntemin daha doğru sonuç verdiği merak edilmiş ve bu amaçla çalışmalar yapılmıştır.

Nokta koordinatlarının başka bir noktaya gerek olmadan belirlenebilmesini sağlayan hassas mutlak konum belirleme (Precise Point Positioning, PPP) yöntemi, kod ve faz ölçülerini birlikte kullanmanın yanı sıra iyonosferden bağımsız lineer kombinasyonları da kullanarak yüksek doğrulukta sonuçlar vermektedir (Gao & Shen, 2001; Kouba & Héroux, 2001; Sezer vd., 2021). PPP yöntemine göre değerlendirme yapan hem akademik (Bernese, GIPSY, vd.) yazılımlar hem de internet tabanlı servisler bulunmaktadır (APPS, CSRS-PPP, GAPS, magicGNSS, Trimble RTX, vd.). Bu servisler kullanılarak birçok araştırma literatüre katkı sağlamıştır (Abdallah & Schwieger, 2016; Ebner & Featherstone, 2008; El-Hattab, 2014; Ghoddousi-Fard & Dare, 2006; Gökdaş & Özlüdemir, 2021; Guo, 2015; Güneş & Demir, 2022; Öcalan vd., 2013; Tsakiri, 2008; Yiğit vd., 2016).

Günümüzde ise GPS'in yanı sıra farklı uydu sistemlerinin kullanılmaya başlanması ile GNSS uydularından elde edilen verilerin değerlendirilmesi ve doğrulukları yeni araştırma konularını da ortaya çıkarmıştır. Bu amaçla IGS (International GNSS Service), farklı uydu verilerinin toplanması ve yayınlanabilmesine olanak sağlamak için MGEX (Multi-GNSS Experiment) projesini gerçekleştirmiştir (Montenbruck vd., 2017). MGEX istasyonlarında GPS, GLONASS, Galileo, BeiDou, QZSS (Quasi-Zenith Satellite System) ve IRNSS (Indian Regional Navigation Satellite System) uydularına ait veriler toplanmaktadır (URL-1).

Yiğit vd. (2016)'da uzun dönem GNSS verileri CSRS-PPP (Canadian Spatial Reference System Precise Point Positioning) servisi kullanılarak değerlendirilmiş ve uzun dönem zaman serilerinden nokta hız ve karesel ortalama hata (KOH) değerleri hesaplanmıştır. Aynı zamanda JPL (Jet Propulsion Laboratory) tarafından hesaplanan zaman serileri kullanılarak hesaplanmış hız ve KOH değerleri karşılaştırılmıştır. CSRS-PPP ile elde edilen hızların KOH değerlerinin JPL'den elde edilen sonuçlara göre daha yüksek olduğu ve buna bağlı olarak JPL'in tekrar edilebilirliğinin daha iyi olduğu sonucuna varılmıştır. Ayrıca CSRS-PPP'nin zaman serilerinin oluşturulması ve hız kestiriminde kullanılabileceği sonucu ortaya konmuştur. Jamieson ve Gillins (2018) yaptıkları çalışmalarında farklı ölçüm sürelerinde GPS ve GLONASS verilerini kullanarak internet tabanlı veri değerlendirme servislerinin doğruluğunu araştırmışlardır. Sadece GPS verisi kullanılarak elde edilen değerlerin servisler tarafından birbirine yakın sonuçlar verdiği belirtilmiştir. Karşılaştırma için kullanılan HRMS (Horizontal Root Mean Squares, yatay karesel ortalama hata) ve VRMS (Vertical Root Mean Squares, düşey karesel ortalama hata) değerleri hesaplanmıştır. HRMS değerlerinin, GLONASS verilerinin kullanılmasıyla iyileştiği, VRMS değeri için ise GPS+GLONASS verilerinin kullanılmasının Trimble RTX servisi ile değerlendirme sonucunun CSRS-PPP servisinden alınan sonuçlardan %10-20 daha küçük olduğu belirtilmiştir. Erol (2021), MGEX ağına ait seçtiği istasyonlarda farklı uydu sistemlerinin verilerini CSRS-PPP servisini kullanarak analizler yapmıştır. 15 dakikadan 24 saate kadar farklı veri toplama sürelerine göre yapılan analizlerde sadece GPS verisi kullanılarak elde edilen koordinat bileşenlerinde sadece GLONASS verisinin kullanıldığı stratejiye göre daha iyi sonuçlar verdiği belirlenmiştir. GPS+GLONASS verilerinin birlikte kullanılmasının elde edilen sonuçlarda özellikle kısa süreli gözlemlerde önem taşıdığı belirtilmiştir. Yurdakul (2023)'ün çalışmasında internet tabanlı servisler kullanılarak kısa ölçüm süresine sahip noktalarda GLONASS verilerinin etkisi araştırılmıştır. 0.5 ile 4 saat arasında değişen veri toplama

sürelerine göre GPS ile birlikte GLONASS'ın ele alınması genel olarak yapılan analiz sonuçlarını %76 kadar iyileştirse de %24'lük bir kısmının negatif etkilendiği sonucuna ulaşılmıştır. [Sezer vd. \(2021\)](#)'de, IGS-MGEX ağında seçili noktalarda Trimble-RTX servisini kullanarak GPS, GLONASS, Galileo ve BeiDou verilerini değerlendirmişlerdir. Dört farklı uydu verisini kombinasyonlar şeklinde incelenmişlerdir. Enlem değeri ve gözlem süresine göre doğruluk fonksiyonları belirlemiş ve fonksiyon parametrelerinin anlamlılıklarını test etmişlerdir. GPS ve GLONASS verileri ile elde edilen konum bilgilerine Galileo ve BeiDou'nun katkı sağladığını bulmuşlardır. Literatürde, farklı uydu verileri kullanılarak yapılan farklı çalışmalar da bulunmaktadır ([Bruyninx, 2007](#); [Gümüş vd., 2023](#); [İnal vd., 2022](#); [Öğütçü, 2019](#); [Vázquez-Ontiveros vd., 2023](#)).

Bu çalışma kapsamında internet tabanlı PPP yöntemine göre veri değerlendiren servislerden biri olan Trimble RTX kullanılmıştır ([Doucet vd., 2012](#); [URL-2](#)). Trimble RTX ile bir noktaya ait GNSS verilerinin gerçek zamanlı (real-time) ya da ölçüm sonrasında (post-processing) verileri değerlendirilebilmektedir. Aynı zamanda, tektonik plakaları da göz önünde bulundurup ölçü epogunda ITRF14 ya da ITRF08 sistemlerinde 3 boyutlu kartezyen ve coğrafi koordinatlar ile birlikte standart sapmalar da elde edilebilmektedir.

Bu çalışmanın temel amacı ise, farklı ölçüm süreleri ve uydu kombinasyonları kullanılarak elde edilen koordinatlardan kestirilen hız değerleri arasındaki ilişkiyi belirlemektir. Bu amaçla, internet tabanlı bir servis olan Trimble RTX ile statik değerlendirme yöntemine göre farklı uydu verilerinden elde edilen sonuçlar kullanılarak seçilen istasyonların (ISTA ve KIRU) hızları En Küçük Kareler (EKK) yöntemine göre kestirilmiştir. Seçilen istasyonlarda 24 saatlik veriler 4'er, 6'şar, 8'er ve 12'şer saatlik epoklara bölünerek GPS (G), GPS+GLONASS (GR) ve GPS+GLONASS+Galileo (GRE) uydu kombinasyonlarına göre değerlendirilmiştir. ITRF14 sisteminde elde edilen 3 boyutlu kartezyen koordinatlar ve standart sapmalar kullanılarak belirtilen her epok ve uydu kombinasyonu için hız değerleri kestirilmiştir.

2. Hız Kestirimi

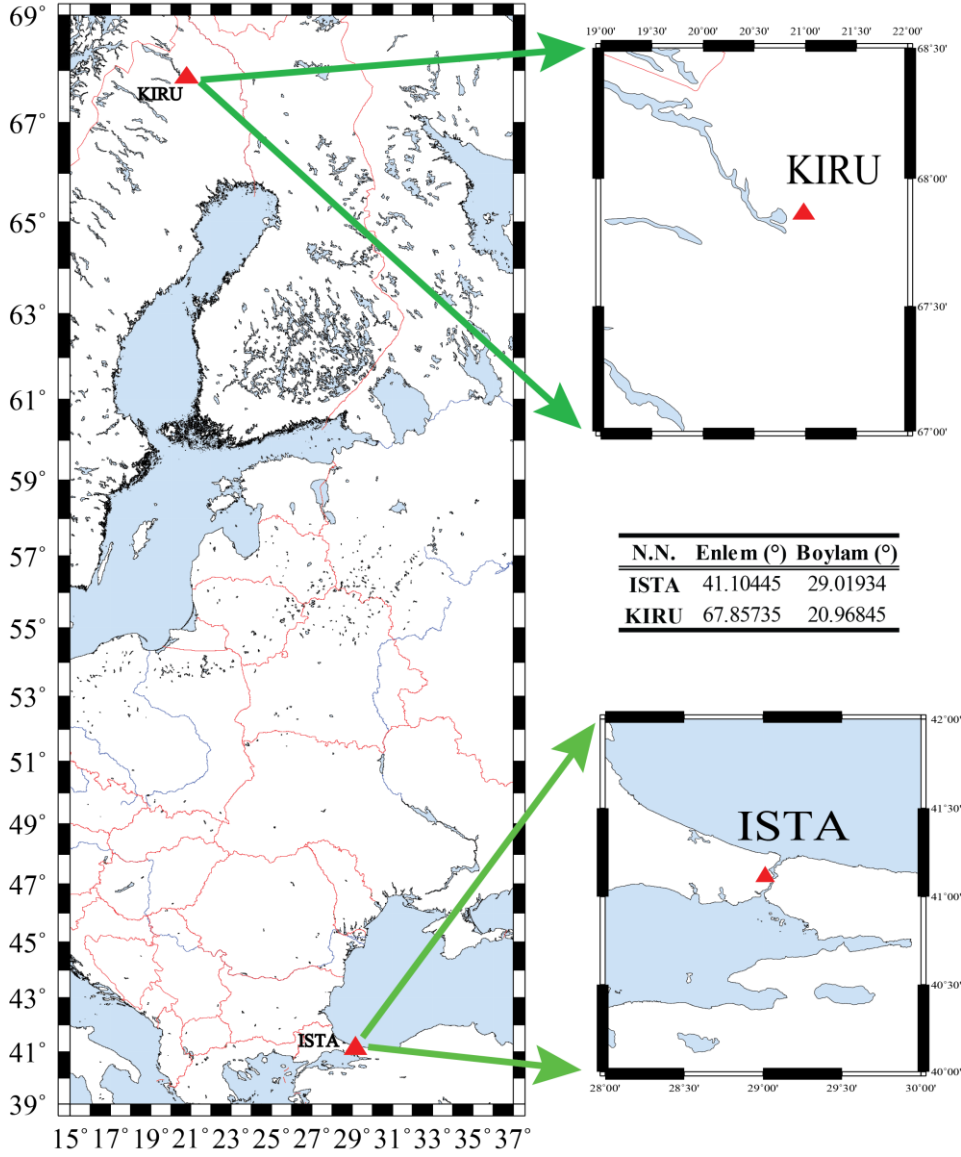
Yeryüvarı üzerindeki her bir noktanın levha tektoniği nedeniyle hareket halinde olması, bu noktaların yıllık olarak ne kadar konum değişimine sahip olduklarını belirleme ihtiyacını ortaya çıkarmıştır. t_0 ilk anında x_0 konumunda olan jeodezik bir noktanın t_i anındaki x_i konumunu elde edebilmek için aşağıdaki doğrusal hız modeli kullanılabilir ([Nocquet & Calais, 2003](#)).

$$x(t_i) + v(t_i) = x(t_0) + \dot{x}(t_i - t_0) \quad (1)$$

Burada $v(t_i)$, t_i anındaki düzeltme değerini; \dot{x} , kestirilmiş hız değerini göstermektedir. (1) numaralı eşitlik kullanılarak EKK dengeleme yöntemine göre noktaların hızları kestirilmektedir. Gerçekleştirilen işlemler sonucunda noktalara ait 3 boyutlu hız değerleri ve standart sapmaları elde edilmektedir. Seçilen noktalarda her yılın aynı günleri kullanılarak mevsimsel etki elemine edilmiştir. Aynı zamanda, sadece noktasal olarak hız değerinin belirlenmesinde farklı uydu misyonlarına ait veriler kullanılarak elde edilen sonuçların karşılaştırılması amaçlanmıştır. Bu nedenlerle hız modeline mevsimsel etkiler ve ivme parametreleri eklenmemiştir.

3. Sayısal Uygulama

Bu çalışmada IGS-MGEX ağına ait 5 yıllık, iyonosferik etkinin az olduğu yılın aynı günlerine (121, 122, 123) ait düzenli verisi bulunan, ülkemizde yer alan ISTA ve İsveç'te yer alan KIRU istasyonları seçilmiştir (Şekil 1). Bu istasyonların 2017-2021 yılları arasında her yıla ait, ardışık üç günlük (121, 122, 123) verileri kullanılarak değerlendirmeler yapılmıştır. Veriler, BKG (Bundesamt für Kartographie und Geodäsie)'den elde edilmiştir ([URL-3](#)).

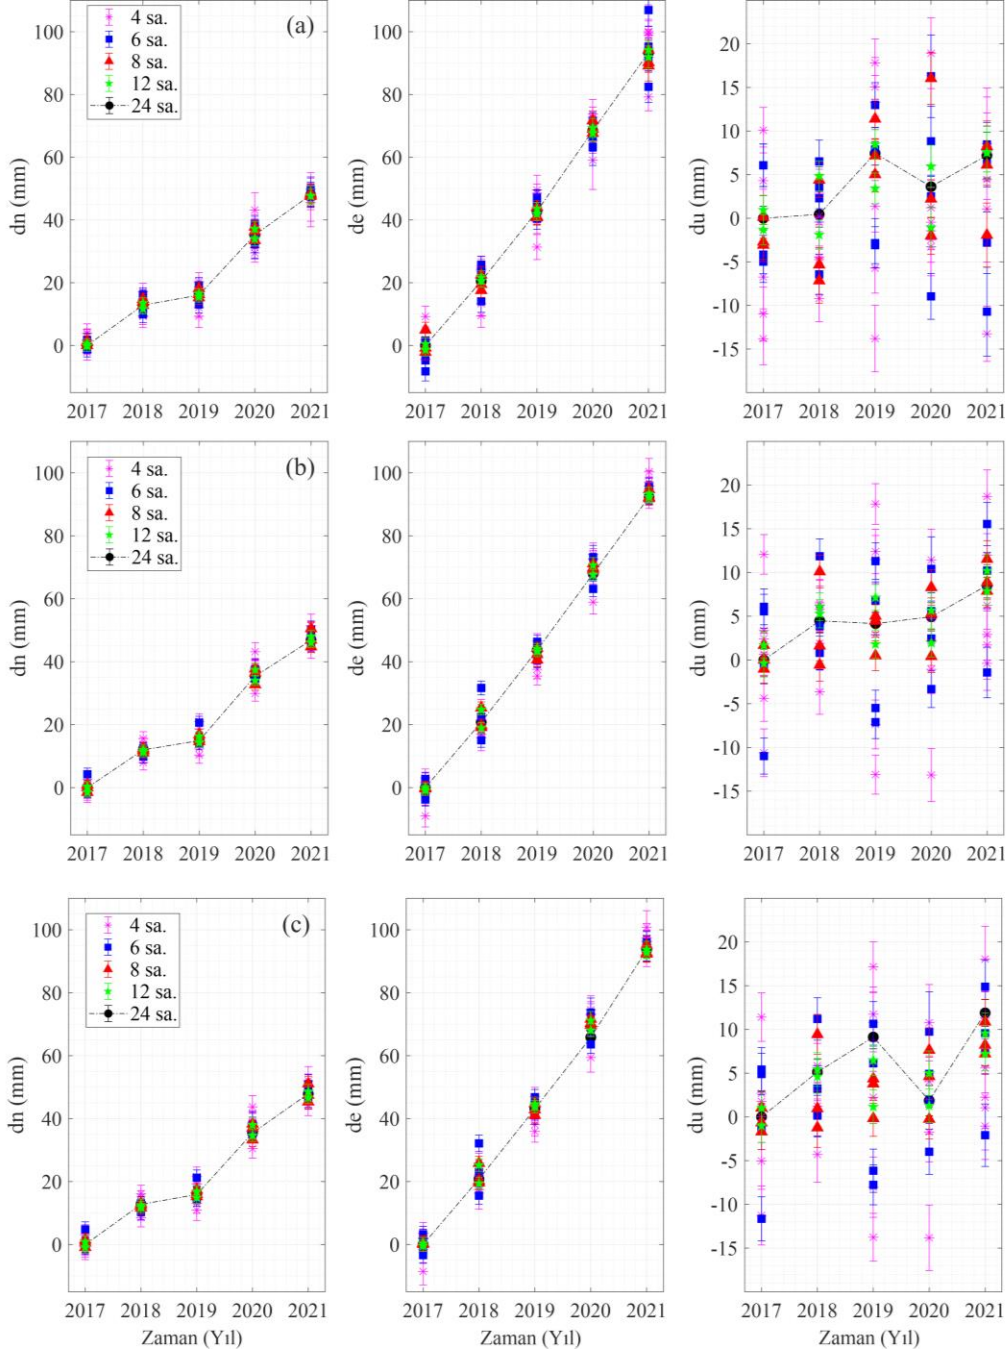


Şekil 1: Çalışmada kullanılan istasyonlar

Verilerin değerlendirilmesi farklı uydu verilerini değerlendirebilen Trimble RTX (URL-2) internet tabanlı veri değerlendirme servisi kullanılarak yapılmıştır. Trimble-RTX servisi, ürettiği yörünge ve saat bilgilerini kullanarak kod ve faz ölçüleri ile analizleri gerçekleştirmektedir. Alıcı ve uydu saat hataları, troposferik ve iyonosferik gecikmeler, plaka hareketleri, uydu ve alıcı anten kayıklıkları, katı yeryuvarı ve kutup gelgitleri, okyanus yüklemesi etkisi, kod ve taşıyıcı faz kayıklıkları ve çok yolluluk hataları, taşıyıcı dalga tamsayı belirsizliği ve rölativistik düzeltmeler göz önünde bulundurularak değerlendirmeler yapılmaktadır (Doucet vd., 2012).

Koordinatlar ITRF14 sisteminde ve ölçü epoğunda elde edilmiştir. Üç günlük alınan verilerin değerlendirme sonuçları arasında istatistiksel olarak anlamlı bir fark olmadığı belirlendikten sonra her yılın seçilen ilk günü (121. gün) kullanılarak analizlere devam edilmiştir. Öncelikle 24 saatlik veriler GPS (G), GPS-GLONASS (GR) ve GPS-GLONASS-Galileo (GRE) veri setine göre ayrı ayrı değerlendirilmiştir. Bu veriler daha sonra Tablo 1'deki ölçüm sürelerine bölünerek değerlendirmeler yapılmıştır. Sonuç olarak her periyodun farklı ölçüm sürelerine göre yapılan analizlerden bir koordinat değeri elde edilmiştir. Elde edilen 3 boyutlu kartezyen koordinat sisteminden, istasyonların coğrafi koordinatları kullanılarak topocentrik koordinat sistemine geçiş yapılmıştır.

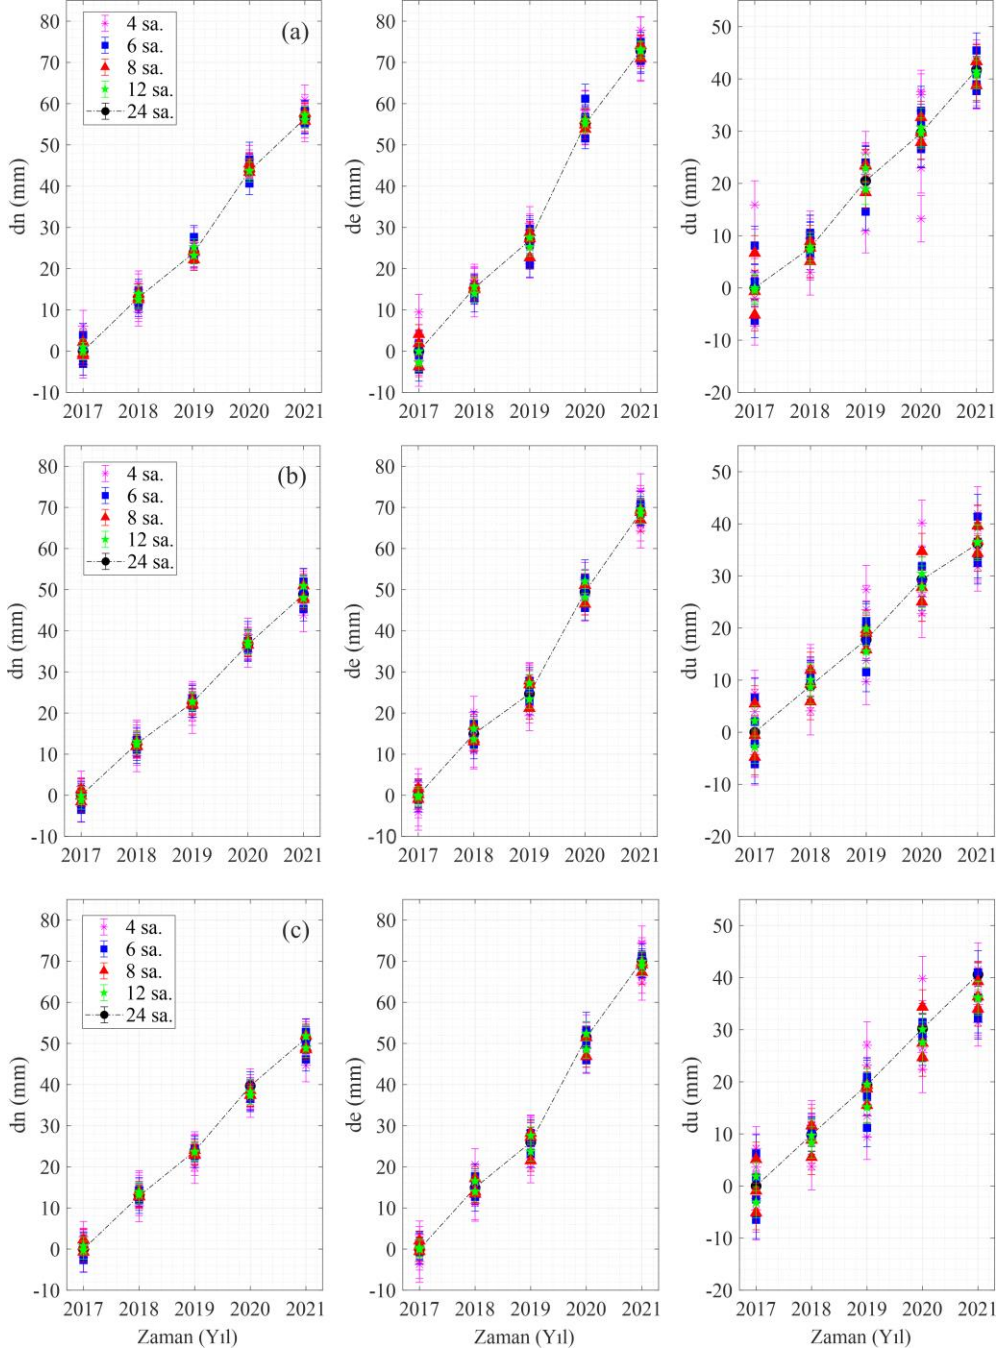
Şekil 2 ve 3'te sırasıyla ISTA ve KIRU istasyonlarına ait zaman serileri verilmektedir. Zaman serilerinde, her yılın aynı gününe ait verilerin Tablo 1'de verilen gözlem sürelerine göre farklı uydu kombinasyonlarına uygun olarak yapılan değerlendirme sonuçları kullanılmıştır. Zaman serileri, istasyonların değerlendirmeye alınan ilk gününe ait 24 saatlik verisi ile elde edilen koordinat değerlerinden, Tablo 1'de yer alan farklı gözlem sürelerine göre elde edilen koordinat değerlerinin farkı alınarak oluşturulmuştur.



Şekil 2: ISTA istasyonuna ait, 24 saatlik (a) GPS (b) GPS+GLONASS (c) GPS+GLONASS+Galileo veri çözümü doğru kabul edilerek diğer epoklardan elde edilen koordinat farkları (dn: kuzey-güney koordinat bileşeni farkları, de: doğu-batı koordinat bileşeni farkları; du: yükseklik bileşeni koordinat farkları) alınarak çizilen zaman serileri.

Şekil 2'de genel olarak (a)'ya bakıldığında kuzey-güney bileşen için fark değerleri yaklaşık olarak 0-50 mm arasında değişmektedir. En büyük değişiklik değerinin 4a epogunda olduğu belirlenmiştir (49.77 ± 3.57 mm). Doğu-batı bileşeninde ise farklar kuzey-güney bileşene göre yaklaşık iki kat daha büyüktür. En büyük değişimin ise 6b epogunda 106.91 ± 5.12 mm

olarak elde edilmiştir. Yatay bileşenlere genel olarak bakıldığında, bütün epoklar arasında bir tutarlılık görülmektedir. Yükseklik bileşenine geldiğimizde ise durum yatay bileşenlerden daha farklıdır. En büyük sıçrama 4c epoğunda tespit edilmesine rağmen, genel olarak saçılımlar bütün epoklarda görülmektedir. Şekil 2(b) ve 2(c) incelendiğinde ise genel olarak nokta konum değişimleri birbirine yakındır. Her iki şekilde de en büyük farklılıklar yatay bileşenler için 4c epoğunda, yükseklik bileşeninde ise 4a epoğundadır.



Şekil 3: KIRU istasyonuna ait, 24 saatlik (a) GPS (b) GPS+GLONASS (c) GPS+GLONASS+Galileo veri çözümü doğru kabul edilerek diğer epoklardan elde edilen koordinat farkları (dn: kuzey-güney koordinat bileşeni farkları, de: doğu-batı koordinat bileşeni farkları; du: yükseklik bileşeni koordinat farkları) alınarak çizilen zaman serileri.

Şekil 3'e gelindiğinde ise KIRU istasyonunun sadece GPS verilerinin değerlendirilmesi ile elde edilen farklarda her iki yatay bileşen için de en büyük farklar 4c epoğunda ($dn=60.95\pm 3.58$ mm, $de=77.78\pm 3.27$ mm) elde edilmiştir. Yükseklik bileşeninde ise 6c epoğunda (45.45 ± 3.36 mm) en büyük fark değeri elde edilmiştir. Şekil 3(b) ve 3(c)'de aynı epoklarda

sırasıyla 6a, 4c ve 4b epoklarında en büyük değişimler elde edilmiştir.

Tablo 1: Çalışmada kullanılan farklı oturum sürelerinin tanımlanması

Gözlem Süresi (sa)	a	b	c	d	e	f
4	00:00-04:00	04:00-08:00	08:00-12:00	12:00-16:00	16:00-20:00	20:00-24:00
6	00:00-06:00	06:00-12:00	12:00-18:00	18:00-24:00		
8	00:00-08:00	08:00-16:00	16:00-24:00			
12	00:00-12:00	12:00-24:00				
24	00:00-24:00					

İstasyonlara ait verilerin zaman serileri elde edildikten sonra hız kestirimi aşamasına geçilmiştir. İstasyonlara ait hız değerleri EKK yöntemi kullanılarak toposentrik koordinat sisteminde (n-kuzey güney, e-doğu batı, u-yükseklik) elde edilmiştir. Temel olarak 3 farklı veri setiyle hız kestirimi yapılmıştır. Öncelikle sadece GPS (G) verileri kullanılarak Tablo 1’de verilen gözlem sürelerine göre değerlendirilip her yılın seçilen ilk gün verisinden elde edilen koordinatlar ve standart sapmaları kullanılarak hız hesabı yapılmıştır. Aynı işlem adımları GPS ve GLONASS (GR) ve daha sonra GPS, GLONASS ve Galileo (GRE) verileri kullanılarak gerçekleştirilmiştir.

3 veri setine göre hız değerleri arasındaki farklar hesaplanmıştır. Her stratejinin kendi iç doğruluğunu belirleyebilmek için kendi 24 saatlik hız değerleri doğru kabul edilerek bütün epoklar arasındaki farklar ve farkların standart sapmaları hesaplanmıştır (Tablo 2). Sadece GPS verisine göre elde edilen farklara bakıldığında ISTA ve KIRU istasyonlarında aynı özelliklerle direk olarak karşılaşılmadığı görülmektedir. Örneğin ISTA istasyonunun kuzey-güney bileşeninde en küçük fark 8a epogunda iken KIRU istasyonunda 6c epogundadır. ISTA istasyonunun doğu-batı bileşeninde en düşük fark 4c epogunda görülürken, en yüksek standart sapma değerinin de yine aynı epokta olduğu görülmektedir. 4’er saatlik epoklar olan 4c ve 4e epoklarında kuzey-güney bileşende sırasıyla en düşük ve en yüksek farklar elde edilmiştir. Yükseklik bileşeninin hız değeri farklarında ise, 4c ve 4d epokları en yüksek değerlere sahiptir. KIRU istasyonunda ise yatay ve düşey bileşenlerinde hem hız değeri farkları hem de standart sapma değerleri ISTA istasyonuna göre oldukça düşüktür. GR’ye göre elde edilen farklara bakıldığında ISTA istasyonundaki fark değerlerinin sadece GPS’e göre daha düşük elde edildiği görülmektedir. Her iki istasyon içinde genel olarak, 4 saatlik epoklardaki farkların standart sapma değerlerinin diğer epoklardan fazla olduğu gözlemlenmektedir. GRE’de ise ISTA istasyonu için yatay bileşen için en büyük farkın 4c epogunda hesaplandığı, en büyük standart sapma değerinin ise yatay ve düşey bileşende 4d epogunda elde edildiği görülmektedir. KIRU istasyonu için ise genel olarak ISTA istasyonuna göre daha stabil bir durumdan bahsedilebilmektedir. Genel olarak fark değerleri ve bunların standart sapma değerleri GR ile elde edilen değerlere yakındır (Tablo 2).


Sonuç olarak hem ISTA hem de KIRU istasyonlarında hız bileşen farklarının istatistiksel olarak anlamlı olup olmadığı t-testine göre kontrol edilmiştir. Her üç veri setine göre hesaplanan kendi 24 saatlik verilere göre hesaplanmış hız bileşen değerlerinin doğru kabul edilip diğer epokların farkları %95 güven düzeyine göre belirlenen sınır değer olan $t_{f,1-\alpha/2} = 2.4469$ ’dan küçük olduğu yani bütün fark değerlerinin istatistiksel olarak anlamsız olduğu belirlenmiştir.

Elde edilen fark değerleri düzenli bir artış ya da azalış gibi bir yapıya sahip olmadıkları için genel olarak yorumlamak zordur. Tablo 2’de yer alan hız farklarının biraz daha kolay yorumlanabilmesi için bu farkların mutlak değerleri alınarak Şekil 4 ve Şekil 5 çizilmiştir. Her iki istasyona ait G, GR ve GRE kombinasyonlarının 24 saatlik hız değerlerine genel olarak, en yakın 12 saatlik hız değerlerinin olduğu, en büyük farkların ise iyonosferik etkinin yüksek olduğu epoklarda olduğu söylenebilmektedir.


Tablo 2: İstasyonların farklı epoklardaki hız değerlerinin kendi 24 saatlik verileri ile elde edilen hız değerlerinden olan farkları

Epoklar	ISTA						KIRU					
	$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)		$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)	
12a	1.01	±2.54	0.23	±3.21	-1.03	±2.63	-0.16	±1.77	0.03	±1.90	0.22	±2.44
12b	-0.25	±3.07	-0.4	±3.67	-0.17	±3.13	0.13	±2.01	0.59	±2.15	-0.63	±2.66
8a	-0.03	±2.45	-0.28	±3.34	-1.86	±2.55	0.45	±1.80	-0.55	±1.97	0.16	±2.47
8b	0.82	±4.32	-0.63	±5.14	1.60	±4.55	0.28	±2.07	0.17	±2.07	1.27	±2.81
8c	0.06	±3.12	1.38	±3.95	0.93	±3.21	0.26	±2.35	0.96	±2.60	-1.28	±2.92
6a	0.72	±2.85	-1.83	±3.85	-1.10	±2.97	0.45	±1.94	-0.75	±2.11	-0.56	±2.48
6b	1.26	±4.07	5.65	±5.35	-3.06	±4.32	-0.17	±2.14	0.80	±2.24	-0.48	±2.78
6c	0.34	±2.74	-3.87	±3.42	-4.88	±2.81	-0.07	±2.28	0.56	±2.47	0.23	±2.93
6d	0.08	±3.11	-0.89	±4.07	1.08	±3.21	0.50	±2.37	0.73	±2.53	-2.27	±2.90
4a	1.51	±3.85	-1.35	±6.10	-0.77	±4.07	1.88	±2.87	-1.41	±3.29	-2.13	±3.33
4b	-0.60	±2.48	4.47	±3.57	-2.67	±2.57	-0.82	±1.99	-0.53	±2.39	-0.08	±2.57
4c	0.62	±5.04	0	±7.78	5.79	±5.32	0.96	±2.42	1.14	±2.46	1.84	±2.91
4d	1.12	±3.54	-5.74	±4.16	-7.46	±3.69	0.92	±2.59	0.07	±2.70	0.65	±3.11
4e	-0.31	±4.88	5.82	±7.23	1.89	±5.05	-0.33	±2.31	0.02	±2.72	-0.55	±2.88
4f	-0.56	±2.77	0.73	±3.75	1.83	±2.88	0.22	±2.57	1.05	±2.87	-1.90	±2.95
Epoklar	$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)		$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)	
12a	0.66	±2.36	1.13	±2.64	0.23	±2.42	0.56	±1.77	-0.28	±1.75	0.22	±2.43
12b	-0.07	±2.03	-1.26	±2.23	-1.05	±2.07	-0.24	±1.77	0.3	±1.83	-0.29	±2.43
8a	0.15	±2.27	0.80	±2.69	-1.01	±2.35	0.94	±1.56	-1.21	±1.61	0.59	±2.16
8b	1.60	±2.12	1.44	±2.39	1.93	±2.18	0.02	±1.51	0.50	±1.54	0.13	±2.11
8c	-0.79	±2.07	-1.22	±2.40	0.49	±2.13	-0.51	±2.20	0.66	±2.25	-0.34	±2.96
6a	0.69	±2.51	-0.12	±3.04	-0.74	±2.61	1.33	±1.68	-0.91	±1.68	0.64	±2.21
6b	1.51	±2.91	3.09	±3.17	-0.76	±2.99	0.16	±2.19	0.45	±2.19	-0.86	±2.88
6c	0.37	±2.22	0.19	±2.54	-0.99	±2.28	0.26	±1.43	0.52	±1.54	-0.40	±1.99
6d	-0.60	±2.80	-3.36	±3.43	1.80	±2.88	-1.17	±1.92	0.25	±2.09	-0.91	±2.57
4a	0.26	±3.07	1.38	±3.77	1.43	±3.23	0.82	±2.22	-1.37	±2.26	-2.13	±2.73
4b	-0.10	±2.13	3.59	±2.71	-3.01	±2.19	0.46	±1.59	-0.60	±1.76	2.06	±2.15
4c	2.17	±3.77	4.61	±4.21	2.37	±3.93	0.18	±2.14	1.60	±2.02	-0.14	±2.67
4d	1.04	±4.12	0.25	±4.90	-1.78	±4.21	0.28	±1.54	-0.13	±1.66	0.25	±2.05
4e	-0.11	±2.93	1.07	±3.65	-2.09	±3.02	0.67	±2.93	0.93	±2.92	0.44	±3.56
4f	0.18	±3.36	-0.61	±4.51	1.08	±3.50	-1.90	±2.09	0.62	±2.39	-2.11	±2.62
Epoklar	$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)		$dv_n \pm Sv_n$ (mm/yıl)		$dv_e \pm Sv_e$ (mm/yıl)		$dv_u \pm Sv_u$ (mm/yıl)	
12a	0.74	±2.49	0.98	±2.76	-0.10	±2.55	0.79	±1.63	-0.68	±1.75	0.49	±2.23
12b	-0.79	±2.89	-0.68	±3.18	0.12	±2.94	-0.21	±1.62	0.28	±1.79	-0.27	±2.23
8a	0.15	±2.51	0.26	±2.87	-1.77	±2.57	1.51	±1.54	-1.36	±1.71	1.11	±2.07
8b	1.09	±2.58	1.11	±2.75	1.76	±2.63	-0.26	±1.45	-0.31	±1.53	-0.19	±1.96
8c	-0.92	±2.56	-0.97	±2.91	0.84	±2.63	-0.49	±1.80	0.13	±2.02	0.53	±2.43
6a	0.71	±2.89	-0.10	±3.31	-2.04	±2.98	1.52	±1.65	-1.20	±1.72	1.23	±2.11
6b	1.28	±2.63	2.58	±2.93	1.23	±2.72	0.07	±1.80	-0.19	±1.86	-0.49	±2.35
6c	0.23	±4.05	0.42	±4.49	-0.35	±4.16	-0.09	±1.39	0.96	±1.61	-1.27	±1.90
6d	-1.23	±2.77	-2.91	±3.27	2.47	±2.85	-0.67	±1.91	-0.24	±2.12	0.69	±2.43
4a	0.74	±3.15	0.50	±3.70	-0.86	±3.27	2.31	±2.36	-0.72	±2.37	-0.02	±2.68
4b	0.12	±2.37	2.40	±2.87	-2.31	±2.42	0.55	±1.39	-1.13	±1.64	1.60	±1.82
4c	3.47	±3.77	7.14	±4.44	0.70	±3.92	0.17	±1.72	0.87	±1.70	-0.45	±2.11
4d	0.82	±6.55	-1.66	±7.76	-3.62	±6.77	-0.47	±1.34	0.07	±1.54	-0.14	±1.77
4e	-0.10	±3.23	0.82	±3.83	-1.64	±3.35	0.07	±2.42	0.98	±2.53	-0.19	±2.83
4f	-0.72	±2.94	-0.65	±3.95	2.42	±3.07	-0.96	±1.85	-0.27	±2.15	0.55	±2.25

*Tabloda yer alan parametreler istatistiksel olarak anlamsız çıkmıştır.



Şekil 4: ISTA istasyonuna ait hız farkları (mutlak değer olarak)




Şekil 5: KIRU istasyonuna ait hız farkları (mutlak değer olarak)

Her stratejinin kendi iç doğruluğundan sonra GPS'e göre 24 saatlik verilerden elde edilen hız değerleri doğru olarak kabul edilerek diğer stratejilerin bütün epokları için elde edilen hız değerlerinin oranları hesaplanmıştır. Şekil 6 ve 7 sırasıyla ISTA ve KIRU istasyonlarına ait değerleri göstermektedir. Yatay eksen Tablo 1'de verilen epokları, dikey eksen ise hız değerlerinin oranlarını göstermektedir. Şekillerde turuncu renkli kesikli çizgi beklenen değer olan 1'i temsil etmektedir.


ISTA istasyonuna ait şekle genel olarak bakıldığında, 24 saatlik veriden elde edilen kuzey-güney ve doğu-batı bileşenlerine ait hız değerlerinin her iki veri seti için de sadece GPS verisi ile elde edilen değerlere yakın olduğu görülmektedir. Daha

detaylı incelendiğinde ise yatay bileşenler için Galileo verisinin sisteme eklenmesiyle beklenen değere daha yakın değerler elde edildiği görülmektedir. Yükseklik bileşeni için ise özellikle 4 saatlik epoklarda saçılmalar dikkat çekmektedir (Şekil 6).



Şekil 6: İSTA istasyonunun G'ye göre 24 saatlik veri değerlendirme sonucu elde edilen hız değerlerinin doğru kabul edilerek GR ve GRE'nin oranları. Bordo çizgi beklenen değeri göstermektedir.

Şekil 7'de KIRU istasyonuna ait 24 saatlik veriden elde edilen değerlerin oranının her üç bileşen için de birbirine yakın olduğu görülmektedir. Aynı şekilde her üç hız bileşeni için de Galileo verisi (GRE) eklenerek elde edilen değerlerin, beklenen değere daha yakın olduğu görülmektedir (Şekil 7).



Şekil 7: KIRU istasyonunun G'ye göre 24 saatlik veri değerlendirme sonucu elde edilen hız değerlerinin doğru kabul edilerek GR ve GRE'nin oranları. Bordo çizgi beklenen değeri göstermektedir.

4. Sonular

Bu alıřmanın temel amacı, farklı lm sreleri ve uydu kombinasyonlarından elde edilen koordinat deęerleri kullanılarak kestirilen hız deęerleri arasındaki iliřkiyi belirlemektir. IGS-MGEX aęında, mevsimsel etkinin elemine edilebilmesi iin her yılın aynı gnne ait 5 yıllık verisi bulunan iki istasyonda uygulamalar gerekleřtirilmiřtir. Bu amala, veri deęerlendirme ařamasında internet tabanlı Trimble RTX servisi kullanılmıřtır. Seilen istasyonların elde edilen koordinat deęerleri ve standart sapmaları kullanılarak, her epok iin hız deęerleri EKK yntemine gre kestirilmiřtir.

Her veri grubu iin 24 saatlik hız deęerleri doęru kabul edilip seilen epoklar arasındaki farklar ve farkların standart sapmaları hesaplanmıř ve 24 saatlik hız deęerleri arasındaki farkların istatistiksel olarak anlamsız olduęu belirlenmiřtir. Stratejiler kendi ierisinde tutarlı sonular verse de 24 saatlik GPS verisinde elde edilen sonulara gre nasıl bir katkı saęladıklarının da ortaya konulması gerekmektedir. Yatay ve dřey hız bileřenleri iin GPS verisine sadece GLONASS verisi eklenerek elde edilen deęerlerde doęruluk dřerken, bu iki veriye Galileo verisi de eklendięinde doęruluk sadece GPS ile elde edilen doęruluęa yaklařmaktadır. Bu nedenle oklu-GNSS verisi zmlerinde GPS'in yanına hangi veri setinin ekleneceęine dikkat edilmelidir.

Teřekkr

alıřmada kullanılan GNSS verileri iin IGS ve BKG'ye teřekkr ederim. izimler Matlab ve Generic Mapping Tools (GMT) (Wessel & Smith, 1998) yazılımları kullanılarak gerekleřtirilmiřtir.

ıkar atıřması Beyanı

Yazar, bu alıřmada bilinen ilgili herhangi bir finansal veya finansal olmayan ıkar atıřması olmadıęını beyan eder.

Kaynaklar

- Abdallah, A., & Schwieger, V. (2016). Static GNSS precise point positioning using free online services for Africa. *Survey review*, 48(346), 61-77.
- Bruyninx, C. (2007). Comparing GPS-only with GPS+ GLONASS positioning in a regional permanent GNSS network. *GPS Solutions*, 11(2), 97-106.
- Doucet, K., Herwig, M., Kipka, A., Kreikenbohm, P., Landau, H., Leandro, R., Moessmer, M. & Pagels, C. (2012). Introducing ambiguity resolution in web-hosted global multi-GNSS Precise point positioning with trimble RTX-PP. *Proceedings of the 25th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS 2012)*, 1115-1125.
- Ebner, R., & Featherstone, W. (2008). How Well Can Online GPS PPP Post-processing Services be Used to Establish Geodetic Survey Control Networks?. *Journal of Applied Geodesy*, 2(3), 149-157.
- El-Hattab, A. I. (2014). Assessment of PPP for establishment of CORS network for municipal surveying in Middle East. *Survey review*, 46(335), 97-103.
- Erol, T. (2021). Web tabanlı CSRS-PPP uygulamasının farklı uydu sistemleri zerindeki performansı. *Jeodezi ve Jeoinformasyon Dergisi*, 8(1), 41-56.
- Gao, Y., & Shen, X. (2001). Improving ambiguity convergence in carrier phase-based precise point positioning. *Proceedings of the 14th international technical meeting of the Satellite Division of the Institute of Navigation (ION GPS 2001)*, 1532-1539.
- Ghoddousi-Fard, R., & Dare, P. (2006). Online GPS processing services: an initial study. *GPS solutions*, 10, 12-20.
- Gkdař, ., & zldemir, M. T. (2021). Velocity estimation performance of GNSS online services (APPS and AUSPOS). *Survey review*, 53(378), 280-288.

- Guo, Q. (2015). Precision comparison and analysis of four online free PPP services in static positioning and tropospheric delay estimation. *GPS solutions*, 19(4), 537-544.
- Gümüő, K., Çelik, C. T., & Gümüő, M. G. (2023). A statistical investigation on the effects of different GNSS systems. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 432-442.
- Güneő, Ö., & Demir, D. Ö. (2022). Comparing results of online GNSS services: A case study from Turkey. *Survey Review*, 54(383), 163-171.
- İnal, C., Bilgen, B., Bülbül, S., & Başbük, M. (2022). Farklı uydu sistemi kombinasyonlarının gerçek zamanlı hassas nokta konumlamaya etkisi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 11(1), 109-115.
- Jamieson, M., & Gillins, D. T. (2018). Comparative analysis of online static GNSS postprocessing services. *Journal of surveying engineering*, 144(4), 05018002.
- Kouba, J., & Héroux, P. (2001). Precise point positioning using IGS orbit and clock products. *GPS solutions*, 5, 12-28.
- Montenbruck, O., Steigenberger, P., Prange, L., Deng, Z., Zhao, Q., Perosanz, F., Romero, I., Noll, C., Stürze, A., Weber, G., Schmid, R., MacLeod, K., & Schaer, S. (2017). The Multi-GNSS Experiment (MGEX) of the International GNSS Service (IGS)—achievements, prospects and challenges. *Advances in space research*, 59(7), 1671-1697.
- Nocquet, J. M., & Calais, E. (2003). Crustal velocity field of western Europe from permanent GPS array solutions, 1996–2001. *Geophysical Journal International*, 154(1), 72-88.
- Öcalan, T., Erdoğan, B., & Tunahöglü, N. (2013). Analysis of web-based online services for GPS relative and precise point positioning techniques. *Boletim de ciencias geodesicas*, 19, 191-207.
- Ögütçü, S. (2019). The contribution of Multi-GNSS Experiment (MGEX) to precise point positioning over Turkey: Consideration of observation time and satellite geometry. *El-Cezeri Journal of Science and Engineering*, 6(3), 642-658.
- Sezer, G., Doğan, A. H., & Erdoğan, B. (2021). Çoklu-GNSS çözümlerinin performansının internet tabanlı Trimble RTX servisi ile incelenmesi. *Jeodezi ve Jeoinformasyon Dergisi*, 8(1), 30-40.
- Tsakiri, M. (2008). GPS processing using online services. *Journal of Surveying Engineering*, 134(4), 115-125.
- Vázquez-Ontiveros, J. R., Padilla-Velazco, J., Gaxiola-Camacho, J. R., & Vázquez-Becerra, G. E. (2023). Evaluation and analysis of the accuracy of open-source software and online services for PPP processing in static mode. *Remote Sensing*, 15(8), 2034.
- Wessel, P., & Smith, W. H. (1998). New, improved version of Generic Mapping Tools released. *Eos, transactions American geophysical union*, 79(47), 579-579.
- Yiğit, C.Ö., Özdemir, B. N., Alçay, S. & Ceylan, A. (2016). CSRS-PPP Yazılımının Uzun Dönemli GNSS Zaman Serilerinin Oluőturulmasında ve Nokta Hızlarının Kestirilmesinde Kullanılabilirliđi. *Harita Dergisi*, 155, 23-31.
- Yurdakul, Ö. (2023). Performance investigation of GLONASS in the static PPP technique with independent short measurement times using online processing services. *Survey Review*, 55(393), 567-577.
- URL-1: <https://igs.org/mgex/>, (Eriőim Tarihi: 1 Aralık 2023).
- URL-2: <https://www.trimblertx.com/>, (Eriőim Tarihi: 20 Kasım 2023).
- URL-3: <https://igs.bkg.bund.de/>, (Eriőim Tarihi: 15 Kasım 2023).

Jeodezi ve Jeoinformasyon Dergisi

Journal of Geodesy and Geoinformation

İÇİNDEKİLER - CONTENTS

ARAŞTIRMA MAKALELERİ / RESEARCH ARTICLES

- Yüksek voltajlı iletim hattı kamulaştırmalarında irtifak bedelinin hesaplanması için yeni bir yöntem önerisi
A new method proposal for calculating the easement price in high-voltage transmission line expropriations 1-18
Seda Nur MARABAOĞLU, Bayram UZUN
- ESRI Land Cover ve Dynamic World arazi örtüsü verilerinin karşılaştırılması: Kıbrıs Adası örneği
Comparison of ESRI Land Cover and Dynamic World: The case of Cyprus Island 19-29
Ömer Gökberk NARİN
- İç mekân harita yapımı için makine öğrenmesiyle nokta bulutlarının sınıflandırılması
Classification of indoor point clouds using machine learning for indoor mapping 30-40
Sena VARBİL, Alper ŞEN
- Examining the accuracy of DEM of difference and 3D point cloud comparison methods: Open pit mine case study
Fark SYM ve 3B nokta bulutu karşılaştırma yöntemlerinin doğruluklarının incelenmesi: Açık maden ocağı örneği 41-50
Nilüfer ÖZDAŞ, Mehmet Güven KOÇAK, Serkan KARAKIŞ
- Coğrafi referanslı sosyal medya verilerinden doğal dil işleme ve derin öğrenme kullanılarak duygu analizi:
Kahramanmaraş depremleri örneği
Sentiment analysis from georeferenced social media data using natural language processing and deep learning:
The case of Kahramanmaraş earthquakes 51-67
Dilan Gözdem DOLU, Alper ŞEN
- Trimble RTX servisi kullanılarak uydu kombinasyonlarının hız kestirimine etkisinin incelenmesi
Investigation of the effect of satellite combinations on velocity estimation by using Trimble RTX service 68-79
Deniz Öz DEMİR

