



2020

Turkish Journal of
Remote Sensing and GIS

Turkish Journal of Remote Sensing and GIS

Türk Uzaktan Algılama
ve CBS Dergisi



Baş Editör / Editor in Chief

Prof. Dr. Halil AKINCI, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yardımcı Editörler / Associate Editors

Doç. Dr. Volkan YILMAZ, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Dr. Öğr. Üyesi Mustafa ZEYBEK, Selçuk Üniversitesi, Konya, Türkiye.

Yabancı Dil Editörü / Language Editor

Doç. Dr. Volkan YILMAZ, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Sorumlu Yazı İşleri Müdürü / Managing Editor

Doç. Dr. Ayşe YAVUZ ÖZALP, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yayın Kurulu / Publishing Board

Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

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

Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.

Prof. Dr. Oğuz GÜNGÖR, Ankara Üniversitesi, Ankara, Türkiye.

Doç. Dr. Sedat DOĞAN, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.

Editör Kurulu / Editorial Board

Prof. Dr. Ali Melih BAŞARANER, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Arzu ÇÖLTEKİN, University of Applied Sciences and Arts Northwestern Switzerland.

Prof. Dr. Arzu ERENER, Kocaeli Üniversitesi, Kocaeli, Türkiye.

Prof. Dr. Bülent BAYRAM, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Türkiye.

Prof. Dr. Çiğdem GÖKSEL, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Derya ÖZTÜRK, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.

Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Fevzi KARSLI, Karadeniz Teknik Üniversitesi, Türkiye.

Prof. Dr. Füsün Balık ŞANLI, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

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

Prof. Dr. İsmail Rakıp KARAŞ, Karabük Üniversitesi, Türkiye.

Prof. Dr. Mehmet ALKAN, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Mehmet Devrim AKÇA, Işık Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.

Prof. Dr. Nesibe Necla ULUÇTEKİN, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Oğuz GÜNGÖR, Ankara Üniversitesi, Ankara, Türkiye.

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

Prof. Dr. Tarkan TÜRK, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.

Prof. Dr. Umut Güneş SEFERCİK, Gebze Teknik Üniversitesi, Gebze, Kocaeli, Türkiye.

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

Doç. Dr. Caner GÜNEY, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Doç. Dr. Esra TUNÇ GÖRMÜŞ, Karadeniz Teknik Üniversitesi, Türkiye.

Doç. Dr. İsmail Ercüment AYAZLI, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.

Doç. Dr. Mehmet Ali YÜCEL, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, Türkiye.

Doç. Dr. Krzysztof STERENCZAK, Instytut Badawczy Leśnictwa, Poland.

Doç. Dr. Nusret DEMİR, Akdeniz Üniversitesi, Antalya, Türkiye.



Editör Kurulu / Editorial Board

- Doç. Dr. Özlem AKAR, Erzincan Binali Yıldırım Üniversitesi, Erzincan, Türkiye.
Doç. Dr. Saygın ABDİKAN, Hacettepe Üniversitesi, Ankara, Türkiye.
Doç. Dr. Sultan KOCAMAN GÖKÇEOĞLU, Hacettepe Üniversitesi, Ankara, Türkiye.
Doç. Dr. Uğur ALGANCI, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
Dr. Öğr. Üyesi Deniztan ULUTAŞ KARAKOL, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Ekrem SARALIOĞLU, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Dr. Öğr. Üyesi Gülten KARA, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Hasan Tahsin BOSTANCI, Gümüşhane Üniversitesi, Gümüşhane, Türkiye.
Dr. Öğr. Üyesi Mustafa ÜSTÜNER, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Dr. Öğr. Üyesi Resul ÇÖMERT, Eskişehir Teknik Üniversitesi, Eskişehir, Türkiye.
Dr. Öğr. Üyesi Ziya USTA, Artvin Çoruh Üniversitesi, Artvin, Türkiye.
Dr. Abdulla M. AL-RAWABDEH, Yarmouk University, Irbid, Jordan.
Dr. Aikaterini KARAGIANNI, Aristotle University of Thessaloniki, Greece.
Dr. Davod POREH, University of Napoli Federico II, Napoli, Italy.
Dr. Manohar YADAV, Motilal Nehru National Institute of Technology (MNNIT) Allahabad Prayagraj, India.
Dr. Mohammed DABBOOR, Environment and Climate Change Canada.
Dr. Serkan URAL, ETH Zurich- Computational Physics, Switzerland.
Dr. Yasemin KUZU SINRAM, Hexagon Geospatial Ltd. USA.



İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ RESEARCH ARTICLES

- Bina Zarfının Termal Görüntüler ile Fotogrametrik Modellenmesi
Photogrammetric Modeling of Building Envelope with Thermal Images
Deniz Sakalp, Özgün Akçay.....1 - 16
- Eskişehir Kent Merkezindeki Trafik Kazalarının Zamana Bağlı Konumsal Analizi
Spatiotemporal Analysis of Traffic Accidents in Eskişehir City Center
Vural Yıldırım, Erdem Yurdakul, Gökben Adana Karaağaç, Merve Koçer, Hakan Uyguçgil.....17 - 32
- Türkiye'deki 2000 – 2021 Yılları Arasındaki Bitki Örtüsü Yangınlarının Mekânsal Analizi
Spatial Analysis of Wildfires in Türkiye between 2000 – 2021
Özer Akyürek.....33 - 46
- İHA Tabanlı 3 Boyutlu Verilere Farklı Perspektiflerde Bakış: İTÜ Ayazağa Kampüsü
Different Perspectives on UAV-Based 3D Data: ITU Ayazağa Campus
Semih Sami Akay.....47 - 63
- İstatistiksel Yöntemlerle Yukarı Karasu Havzası'nın Kuzeydoğu Bölümünün (Erzurum) Heyelan Duyarlılık Analizi
Landslide Susceptibility Analysis of the Northeastern Part of the Upper Karasu Basin (Erzurum) Using Statistical Methods
Erdem Aydoğan, Serhat Dağ.....64 - 82
- İHA'larda Kamera Kalibrasyonunun Ortofoto Konum Doğruluğuna Etkisi
Effect of Camera Calibration Refreshing on Orthophoto Position Accuracy in UAV Mapping
Cumhur Şahin.....83 - 99
- Denetimli Sınıflandırıcılarla Taşkın Haritalaması: 2021 Gediz Ovası Seli
Flood Inundation Mapping with Supervised Classifiers: 2021 Gediz Plain Flood
Enis Arslan, Serkan Kartal.....100 - 113
- Kayseri'de Çoklu Regresyon ve Coğrafi Ağırlıklı Regresyon Yöntemleri ile Konutların Toplu Değerlemesi
Mass Appraisal of Residential Units in Kayseri with Multiple Regression and Geographically Weighted Regression Methods
Mehmet Fatih Toprak, Oğuz Güngör.....114 - 124

Bina Zarfının Termal Görüntüler ile Fotogrametrik Modellenmesi

Photogrammetric Modeling of Building Envelope with Thermal Images

Deniz Sakalp¹, Özgün Akçay^{2*}

¹Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Harita Mühendisliği Anabilim Dalı, 17100, Çanakkale/Türkiye.

²Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 17100, Çanakkale/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Özgün Akçay
akcay@comu.edu.tr

doi: 10.48123/rsgis.1166498

Yayın süreci

Geliş tarihi: 24.08.2022
Kabul tarihi: 25.01.2023
Basım tarihi: 28.03.2023

Özet

Termal kameralı İnsansız Hava Araçları (İHA) görüntüleri ile üretilen nesne yüzey sıcaklıkları ve üç boyutlu geometrileri günümüzde pek çok uygulama alanında kullanılmaktadır. Başlangıçta kullanımı sadece askeri alanla sınırlanan insansız hava araçlarının düşük maliyet, hız ve tekrarlı uçuş kabiliyeti nedeniyle küçük alanlarda sıkça tercih edilmektedir. Yalıtım sistemlerinin arızaları, beklenmedik sıcaklık değişimlerini ve artan enerji tüketimini tetikleyen sonuç olarak cephe yapısını doğrudan etkileyen bir enerji akışına olanak tanır. Bu ısıl köprüler termal kameralar ile görüntülenerek bina ısı kaçaklarının kolayca belirlenmesini mümkün kılmaktadır. Termal görüntüleme geniş kullanımına rağmen, dar görüş alanı ve mekânsal çözünürlüğünün düşük olması nedeniyle sınırlıdır. Çalışmada, Ankara ilinin Gölbaşı ilçesinde yer alan bir binanın görünür ve termal görüntüleri insansız hava aracı ile elde edilerek inceleme için yeni bir yaklaşım benimsenmiştir. Bu yaklaşım, İHA'ya monte iki kameradan elde edilen termal ve görünür görüntülerden Structure from Motion (SfM) tekniğine dayalı üç boyutlu tek bir model oluşturulmasına dayanmaktadır. Bu çalışma sonucunda görünür ve termal verilerin eş-kayıt edilmesi sayesinde elde edilen fotogrametrik model ile bina incelemenin ve yorumlamanın elverişli olduğu görülmüştür.

Anahtar kelimeler: İHA, Termal sensör, Görüntü füzyonu, Fotogrametri

Abstract

Object surface temperatures and three-dimensional geometries produced with thermal camera images of Unmanned Aerial Vehicles (UAV) are used in many application areas nowadays. Unmanned aerial vehicles, which were originally limited to military use, are preferred in small spaces due to their low cost, speed, and repetitive flight capability. Failures of insulation systems allow an energy flow that directly affects the facade structure, triggering unexpected temperature changes and increased energy consumption. These thermal bridges can be viewed with thermal cameras, making it possible to easily identify building heat leaks. Although thermal imagery has been used in a wide range, it is limited due to low spatial resolution and narrow field of view. In the study, a new approach has been adopted for the examination by obtaining the visible and thermal images of an unmanned aerial vehicle of a building in the Gölbaşı district of Ankara. This approach is based on the creation of a single three-dimensional model based on the Structure from Motion (SfM) technique from thermal and visible images obtained from two cameras mounted on the UAV. As a result of this study, it has been seen that the building examination and interpretation are convenient with the photogrammetric model obtained by co-registering the visible and thermal data.

Keywords: UAV, Thermal sensor, Image fusion, Photogrammetry

1. Giriş

Gelişmiş ve gelişmekte olan birçok ülke, nüfusuna oranla daha fazla enerjiye ihtiyaç duymaktadır. Ülkemizde tüketilen enerjinin yaklaşık yüzde otuz beşinin binalarda kullanıldığı belirtilmektedir (İMO, 2015). Enerjinin en çok tüketildiği alanlardan biri olan yapılarda ısı yalıtımı uygulamalarının enerji tasarrufu sağlaması, korozyonu önlemesi, zararlı gaz emisyonlarının azaltılması gibi birçok faydası ifade edilmektedir (Bektaş vd., 2017). Enerji üretimindeki zorluklara karşılık artan enerji ihtiyacı, binalardaki enerji tüketiminin düşürülmesi ve verimliliğinin artırılması konularında önemli bir gereksinimi ortaya çıkarmıştır. Özellikle binalarda enerji verimliliğinin artırılması için binaların dışarıya veya ısıtılmayan bölümlerine bakan duvar, çatı, döşeme, cam, havalandırma vb. unsurlarına doğru bir ısı yalıtım uygulaması önerilmektedir (Bayraktar ve Bayraktar, 2016). Binalarda ısı yalıtımının gereksinimlerinin hesaplanması ve uygulanması sırasında başvuru kaynağı olarak TS 825 Binalarda Isı Yalıtımı Kuralları Standardı önemli bir rehber niteliği taşımaktadır. (TSE, 2013). Demir (2011) çalışmasında ifade edilen sürdürülebilir enerji kavramına dayalı olarak, bina enerji yönetiminin sürdürülebilir normlar ile uyumunun sağlanması için bir bina ısı gözlem teknolojisi ihtiyacı öne çıkmıştır. Binanın yüzey sıcaklıkları termal görüntüleme kullanılarak elde edilebilir ve binanın ısı performansı üç boyutlu görselleştirme ile belirlenebilir. Termal görüntüleme, binalardaki ısı sızıntılarını, yüzey nemini ve yapısal sorunları tespit etmek için basit ve etkili bir yaklaşımdır (Kyllili vd., 2014). Termal kamera ile çıplak gözle ve dijital kameralarla belirlenemeyecek tespit ve analizler yapılabilmesi mümkündür. Termal görüntüleme bu özelliği ile bina yorumlama, mekaniksel ve elektriksel bakım, yangın saptama, tıp gibi birbirinden farklı pek çok alanda kullanıma sahiptir (Rakha ve Gorodetsky, 2018). Örneğin bilgisayar donanımlarının kullanıma bağlı oluşan sıcaklık dağılımının belirlenmesi (Durgut ve Akçay, 2016), bina enerji simülasyonlarının oluşturulması (Kim vd., 2015) bazı termal uygulama alanlarına ilişkin çalışmalar olarak sayılabilir. Bu değerlendirmeler ışığında, insansız hava aracı ile nesnenin çoklu sensörlü verisinin elde edilmesi uzaktan algılama ve yakın resim fotogrametrisi için büyük bir potansiyele sahiptir.

Termal görüntülerin çeşitli analizlere sağlayacağı katkılar oldukça değerlidir ancak üç boyutlu modelleme üretiminde gerekli nokta eşleşmesinde zorluklar mevcuttur. Bu nedenle İHA temelli termal görüntüleme ve uzaktan algılama uygulamalarında kullanımı kısıtlanmıştır (Gade ve Moeslund, 2014). Bu kısıtlamalar altında, Sledz vd. (2018) yaptığı araştırmada Dijital Yüzey Modeli (DYM) ve ortofoto gibi fotogrametrik çıktılar için termal görüntülerin kullanılma potansiyelini incelemiştir. Özellikle, termali de içeren çok sensörlü kameraları ile İHA'lar, dijital bina modeli oluşturmak ve yüzey sıcaklık bilgisi üretmek suretiyle bina bilgi modeli oluşturulmasına ve bina sürdürülebilirliğine katkı sağlar (Han ve Huh, 2019). Lagüela vd. (2012) bina yüzeyi termal analiz çalışmasında sadece fotogrametrik modelin son adımı olan ortomozaik görüntüleri birleştirmeyi denemiştir. Görüntü temelli dokulandırma teknikleri kullanılarak İHA ile elde edilen görüntülerin işlenmesi sonucu iki boyutlu görüntüye kıyasla görselleştirmeyi arttıran yüksek çözünürlüklü üç boyutlu yoğun nokta bulutu üretilebilir (Javadnejad vd., 2020). Bu yöntemin avantajlı olmasının nedenlerinden biri, RGB görüntülerin termal görüntülerden çok daha yüksek spektral çözünürlüğe sahip olması nedeniyle üç boyutlu model üretmek için Structure from Motion (SfM) tekniğinin kullanılmasıdır. SfM, metrik olmayan ticari sınıf kameralar ile yeterli oranda bindirilmiş resimlerden nokta bulutları ve ortofotolar gibi yüksek çözünürlüklü haritalama ürünlerinin elde edilmesinde geniş ölçekte kullanımını sağlayan nispeten yeni bir fotogrametrik yaklaşımdır (Javadnejad vd., 2020). Binanın termal görüntülerle dokulandırılmış RGB yoğun nokta bulutunun üretilebilmesi için termal ve RGB kamerasının odak uzaklığı ve sensör boyutu gibi geometrik koşullar sağlanmalıdır. Bunun yanı sıra uçuşun gerçekleştirildiği hava koşulları, uçuş yüksekliği ve iyi bir görüntü eşleme için binanın tüm cephelerinin yüksek bindirmeli olarak çekilmesi hususu da önem taşımaktadır. Termal görüntülerin çözünürlüğünün düşük olması ve yüksek oranda gürültü içermesi nedeniyle doğrudan özellik saptama ve görüntü eşleme tekniklerinin uygulanması durumunda, üç boyutlu model üretimi için yeterli eşleşme noktaları üretilemez. Bu durum, termal görüntülerin görüntü kaydını ve üç boyutlu nokta bulutu üretimini zorlaştırmaktadır. Eşleşmiş görüntü çiftlerini arttırmak için termal ve görünür görüntüler ile görüntü füzyonu gerçekleştirilmelidir. Görünür görüntülerden elde edilen yoğun nokta bulutu, termal mozaik ile dokulandırılarak üç boyutlu füzyonu gerçekleştirilmiş model kaydedilebilir.


İlgili çalışmalar ele alındığında, Han ve Huh (2019) yaptığı çalışmada RGB ve termal modelleri ayrı değerlendirdiği görülmektedir. Bu durum iki model arasındaki geometrik kıyaslamada doğruluk problemi ortaya koymaktadır. Diğer yandan, Javadnejad vd. (2020) çalışması incelendiğinde, termal nokta bulutunu doğrudan oluşturmadan, RGB ve termal görüntüler arasında iki boyutlu dönüşüm ile üç boyutlu termal bilginin elde edildiği görülmektedir. Ayrıca termal görüntüler arasında radyometrik tutarsızlıklara neden olan radyometrik düzeltmenin uygulanmadığı anlaşılmaktadır. Bu çalışmada, RGB ve termal ortak üç boyutlu noktalar seçilerek modellerin birleştirilmesi sağlanmıştır. Ayrıca termal görüntülere normalizasyon uygulanarak kendi aralarındaki radyometrik bozukluklar iyileştirilmiştir. Bu uygulamayı gerçekleştirmek için İHA'ya monte edilen RGB ve termal sensörlere sahip kameralar içeren bir sistem kullanılmıştır. Oluşturulan model bina enerji performansının hızlı bir şekilde tanımlanmasını sağlamaktadır. Makalede, bölüm 2.1 veri kazanımı ve kullanılan araçları açıklamaktadır. Bölüm 2.2'de görünür görüntülerden elde edilen yoğun nokta bulutu üretimi, termal görüntülerin sıralanıp hizalanması ile elde edilen termografik mozaikin üretimi ve RGB yoğun nokta bulutunun termal mozaik ile dokulandırılması sonucu elde edilen bulguları ve analiz sonuçlarını içermektedir.

Bölüm 2.3’de ise RGB ve termal modellerin füzyonu açıklanmıştır. Son olarak bölüm 3’te çalışmada önerilen yöntemin performansına değinilmiştir.

2. Materyal ve Yöntem

Termal kamera, insan gözü ve dijital kameralar aracılığıyla belirlenemeyecek tespit ve analizler yapılabilmesini mümkün kılmaktadır. Termal görüntüleme ile ısı kaçaklarını tespit etmek basit ve etkili bir yaklaşımdır. Sözü edilen fotogrametrik yöntem, ana hatlarıyla Şekil 1’de gösterilmiştir. Çalışma, yüksek çözünürlüklü RGB görüntülerle nispeten düşük çözünürlüklü termal görüntülerin eş kayıt edilmesi ile sıcaklık bilgisi ve geometrik bilginin basitleştirilmiş füzyonuna dayanmaktadır.

Termal görüntülerin kullanımı farklı kamera teknolojileri dikkate alınarak kullanılabilir. Bu çalışmada elde edilen ham termal görüntülerin kamera konumlarını içeren EXIF meta verisi eklenmesi ve görüntülerin relatif sıcaklık göstergelerinin kendi aralarında standartlaştırılması gerekir. Bu ön işlem sonrası, elde edilen termal ve orijinal RGB iki boyutlu görüntülerden, temeli SfM fotogrametrisi yöntemine dayanan Agisoft Metashape programı ile üç boyutlu nokta bulutları ayrı ayrı üretilmiştir. Daha sonra, termal seyrek nokta bulutu ile yüksek çözünürlüklü RGB seyrek nokta bulutunun füzyonu gerçekleştirilmiştir. Füzyon işlemi her iki modelin belirgin ortak noktaları manuel olarak tespit edilerek oluşturulmuştur. Füzyonu gerçekleştirilmiş RGB-Termal seyrek nokta bulutunun ardından sırası ile yoğun nokta bulutu ve RGB-Termal yüksek çözünürlüklü katı modeli üretilmiştir. Üretilen katı model ile binanın yalıtım durumunu incelemek elverişlidir. Önerilen yöntem, fotogrametrik teknikler kullanılarak söz konusu binanın termografik görüntülerinin sıralanıp hizalanması ile dokulandırılmış yüksek çözünürlüklü üç boyutlu model kaydı ile görüntü füzyonunu mümkün kılmaktadır. Elde edilen nihai ürün, bina ısı yalıtım sistemlerinin eksiklerinin ortaya konması için otomatik bir sistem niteliği taşımaktadır. Tüm işlem adımları bir sonraki bölümde sırasıyla daha detaylı anlatılmıştır.



Şekil 1. Görüntü füzyonu için işlem adımları

2.1 Veri Kazanımı

Çalışmanın amacı, RGB ve termal görüntülerin kombinasyonu ile sırayla gerçekleştirilmesi gereken fotogrametrik işlem adımlarına bağlı olarak uygun bir veri toplama yöntemiyle görünür görüntülerden elde edilen yoğun nokta bulutunun termal görüntülerle dokulandırılıp binanın ısı yalıtım değerlerini gözlemlemektir.

Çalışma, Türkiye'nin başkenti Ankara'nın Gölbaşı ilçesi Örencik mahallesinde gerçekleştirilmiştir. Çalışma bölgesi Şekil 2'de uydu görüntüsünde görülmektedir. Konut bölgesinde yer alan betonarme 5 katlı bina, çatı, duvar yapısı ve etrafında bulunan ağaç ve araba sayısı azlığı nedeniyle tercih edilmiştir. Ayrıca, bina cephelerinin yalıtım malzemesi içermesi, cam kaplama gibi yansıma özelliğine sahip malzemelerin cephelerde fazla olmaması, çatının açık şekilde gözlemlenebilir olması, binanın başka bir bina ile bitişik nizam olmaması ve binanın müstemilat içermemesi fotogrametrik değerlendirme açısından belirlenen başlıca kriterlerdir.



Şekil 2. a) Çalışma alanının Google Maps uydu görüntüsü b) binanın İHA görüntüsü

Çalışmada kullanılan İHA pek çok alanda kullanılan hassas alçak irtifa İHA platformu olan DJI Phantom 4 RTK'dir (Nex ve Remondino, 2014). Kullanılan çoklu sensörlü kamera ise yüksek çözünürlüklü RGB sensöre sahip aynı zamanda termal görüntüleme sağlayan Yuneec E10Tx'dir. Veri seti, enine ve boyuna %80-90 yüksek bindirme oranlı olarak Yuneec E10Tx kamerası ile ortalama 60.5 metre yüksekliğinde kazanılmıştır. Söz konusu binanın ve yakın çevresinin modellenebilmesi için uygun hava koşullarında ve yükseklikte nadir ve oblik olarak görüntülerin alımı 18 Kasım 2020 tarihinde saat 13:30'da gerçekleştirilmiştir. Veri alımı sırasında çevresel koşullar da etkilidir. Özellikle termal görüntülerde ışın yansıma hatalarının optimum ölçekte olması için rüzgar hızının ve sıcaklığın uygun, yağmurun yağmadığı bir havada görüntüler temin edilmiştir. Böylelikle görüntü alımı sırasında meydana gelebilecek hata değerleri ve bakış açısı farklılıkları nedeniyle oluşabilecek düşük eşlenik nokta sayıları iyileştirilmektedir. Fotogrametrik değerlendirme amaçları için sıklıkla kullanılan Agisoft Metashape programı, alımı gerçekleştirilen iki boyutlu dijital görüntülerin üç boyutlu konumsal verisini üretmeyi sağlamaktadır.

RTK donanımlı İHA'lar yardımıyla herhangi bir yer kontrol noktası tesisine gereksinim duyulmadan doğrudan hassas konum belirleme ile yüksek doğruluklu ortofotolar, nokta bulutları ve sayısal yükseklik modelleri üretilebilmektedir (Tarık ve Öcalan, 2020). Bu nedenle çalışma kapsamında yer kontrol noktası tesis edilmemiştir. Kullanılan çoklu sensörlü kameranın teknik özellikleri Tablo 1 ve 2'de gösterilmiştir.


Tablo 1. Görünür veri kazanımı için kullanılan RGB kameranın özellikleri

| Kamera | Yuneeç E10TvX |
|-----------------------|------------------|
| Renk Hassasiyeti | RGB |
| Resim Boyutu | 1920x1080 piksel |
| Odak Uzaklığı | 23 mm |
| Görüş Alanı | 89.6° |
| Yer örnekleme aralığı | ~6 cm/piksel |


Tablo 2. Termal veri kazanımı için kullanılan kameranın özellikleri

| Kamera | Yuneeç E10TvX |
|-----------------------|---------------|
| Renk Hassasiyeti | Termal |
| Resim Boyutu | 640x512 |
| Odak Uzaklığı | 6.3 mm |
| Görüş Alanı | 32° |
| Yer örnekleme aralığı | ~11 cm/piksel |

Fotogrametrik kısıtlar göz önünde bulundurularak elde edilen yüksek bindirme oranlı çekilmiş RGB ve termal görüntü örneği Şekil 3 ve 4'te gösterilmiştir.



Şekil 3. a) Yuneeç E10TvX kamerası ile çekilmiş yüksek bindirmeli oblik çekilmiş iki RGB görüntü (a ve b)



Şekil 4. Yuneeç E10TvX kamerası ile eş zamanlı çekilmiş RGB görüntü (a) ve termal görüntü (b)

2.2 Veri İşleme

Binanın enerjisiyle ilgili yorum ve incelemeleri gerçekleştirmek amacıyla üretilen termal modeller, nem alanları, ısı kayıpları gibi anormal termal alanları belirleyebilmek için üretilmektedir. Bunun yanı sıra modelin üç boyutlu geometrik bilgisi de anormal termal alanları konumlandırma imkânı sağlamaktadır. Özellikle büyük alanlar söz konusu olduğunda termal modellerin avantajları olmasına rağmen fotogrametrik zorluklar nedeniyle kullanımı kısıtlanmıştır.

İlk olarak, termal kameranın çözünürlüğü RGB kameralara kıyasla düşüktür. Bu durum görüntülerin nokta eşlemesi esnasında kilit nokta çıkarımını olumsuz etkilediği gibi üç boyutlu modelin de kalitesini düşürmektedir. Ek olarak, termal görüntüler görüntü yakalama sırasında dar görüş alanı nedeniyle meydana gelen termal gradyent renk kodlamasından dolayı pürüzlü ve bulanık olduğu için tek başına termal görüntüleri işlemek zorlayıcıdır (Ham ve Golparvar-Fard, 2013). Çalışmada, nihai yüksek çözünürlüklü katı modelin üretilebilmesi için yer kontrol noktası gibi hassas mutlak bir nokta konumuna ihtiyaç duyulmaz. Bu nedenle, RTK (Real Time Kinematic) donanımlı bir insansız hava aracına monte edilen çoklu sensörlü kamera ile eş zamanlı olarak elde edilen RGB ve termal görüntülerin Agisoft Metashape yazılımı kullanılarak iç ve dış yönelmeleri demet dengelemesi ile gerçekleştirilmiştir. Ancak fotogrametrik işlemler öncesi termal görüntülerin üretildikleri kamera teknolojisine dayalı kalibrasyon, normalizasyon, konum etiketlerinin eklenmesi gibi bazı ön veri işlemleri önem taşımaktadır.

2.2.1 Termal verilerin ön işleme


Yunec 10TVX termal kamera ile iki farklı formatta görüntü kaydı alınmıştır. Birincisi jpeg formatında, ikincisi ise tiff formatındadır. jpeg formatlı görüntü doğrudan nesnelerin sıcaklık bilgilerini göstermesine rağmen sadece görsel analiz için üretilmiştir ve fotogrametrik değerlendirmeye uygun değildir. Çünkü görüntüler arasında sıcaklık görselleştirmeleri arasında tutarsızlıklar vardır. Diğer tiff formatı ise fotogrametrik değerlendirmeye uygun kaydedilen görüntülerdir. Bu görüntüler gri tonlarda üretilmektedir ve çıplak gözle detayları ayırmak imkansızdır. Bu çalışmada tiff görüntüler ön işleme sonrası fotogrametrik değerlendirmeye dahil edilmişlerdir. Bu ön işlemenin birinci adımı, tiff görüntülerin eksik EXIF verilerini tamamlamak gereğidir. Özellikle görüntü konum bilgileri tiff görüntüler yerine jpeg görüntülerde yer almaktadır. Bu çalışmaya özel yazılan Python kodları ile EXIF verileri jpeg görüntülerden tiff görüntülere kopyalanmıştır. Bunun avantajı dengelemede ön bilgi olarak konum bilgilerinin kullanılmasının sağlanması ve daha sağlam bir yönelme elde edilmesidir. İkinci ön işlem adımı ise tiff görüntüler arasında standardizasyonun sağlanması ve görselleştirmenin çıplak gözle görünür hale getirilmesidir. Bu kamera görüntüleri radyometrik bir kalibrasyon işleminden geçirilmemiştir. Bu nedenle aynı sahneye ait iki termal görüntü arasında yer yer önemli düzeylerde radyometrik farklılıklar gözlenmektedir. Bu sorunun etkisini azaltmak için iki yöntem irdelenmiştir. Birincisi lokal standardizasyon olarak adlandırdığımız görüntünün radyometrik olarak tek başına 0-255 aralığına ölçeklenmesi diğeri ise global standardizasyon olarak adlandırdığımız tüm görüntüler arasında belirlenen maksimum ve minimum değerler belirlenerek tüm görüntülerin bu uç değerlere göre radyometrik ölçeklenmesidir. Sırasıyla standardizasyon yapılmamış tiff, lokal standardizasyon yapılmış tiff ve global standardizasyon yapılmış tiff görüntüler fotogrametrik olarak değerlendirilerek karşılaştırılmıştır (Tablo 3). Buna göre üretilen otomatik bağlantı sayıları ve üç boyutlu nokta sayıları değerlendirildiğinde her iki standardizasyonun radyometrik iyileştirme sağlamaları nedeniyle nokta eşleme sayılarının arttırdığı görülmektedir. Fotogrametrik füzyon işlemleri için her iki standardizasyon arasında anlamlı bir fark olmasa da lokal standardizasyon uygulanmış görüntüler tercihen kullanılmıştır.

Tablo 3. Standardizasyonun fotogrametrik değerlendirme sonuçlarına etkisi

| Kullanılan termal görüntü türü | Bağlantı nokta sayısı | Üç boyutlu nokta sayısı |
|-----------------------------------|-----------------------|-------------------------|
| Standardizasyon uygulanmamış | 11904 | 35000 |
| Lokal standardizasyon uygulanmış | 13449 | 42324 |
| Global standardizasyon uygulanmış | 13399 | 42333 |

2.2.2 RGB ve termal seyrek nokta bulutlarının üretimi

Çalışmada kullanılan programın temeli olan SfM algoritması, görüntülerin otomatik nokta çıkarımı ile başlamaktadır. Çeşitli nokta çıkarımı algoritmalarından biri olan özellik tabanlı nokta çıkarımı algoritması Scale Invariant Feature Transform (SIFT), aynı bölgeyi kapsayan görüntüler arasında büyük oranlarda değişiklik gösterebilen dönüklük, öteleme ve ölçek gibi konumsal dönüşüm parametrelerinden bağımsız, görüntü alım noktası konum değişimi ve yüzey aydınlanma farklılıklarından kısmen bağımsız olarak çalışabilmesi nedeniyle yaygın olarak kullanılmaktadır (Su vd., 2017). Seyrek nokta bulutu ise demet dengelemesi prosedürleri aracılığıyla kameranın iç ve dış yönelme değerleri olduğu gibi anahtar noktaların üç boyutlu konumundan eş zamanlı çözümü ile üretilir (Snavely vd., 2006). Fotogrametrik kıyımlandırma için kullanılan program SIFT algoritması ile özellik tanıma vektörleri aracılığıyla her bir görüntüye bağlantı noktaları atamaktadır. RGB ve termal görüntü örneğinde bağlantı noktaları Şekil 5' de gösterilmiştir.




Şekil 5. a) RGB bağlantı noktaları b) termal bağlantı noktaları

İki boyutlu görüntü noktalarının çıkarımı ve eşlemesine dayalı olarak demet dengelemesi gerçekleştirilerek bu noktaların üç boyutlu koordinatları üretilmektedir. İlk aşamada üretilen bu nokta bulutu görüntülerin en iyi şekilde yönlendirilmesine yönelik olarak belirlenen model noktalarıdır ve tüm alanın nokta bulutunu üretmeyi amaçlamaz. Optimum bir performans için otomatik nokta eşlemesine dayanan fotogrametrik model için 40000 nokta ve 4000 eşlenik nokta limit olarak belirlenmiştir. Üretilen RGB ve termal seyrek nokta bulutları Şekil 6 ve Şekil 7’de verilmiştir.




Şekil 6. RGB seyrek nokta bulutu



Şekil 7. Termal seyrek nokta bulutu

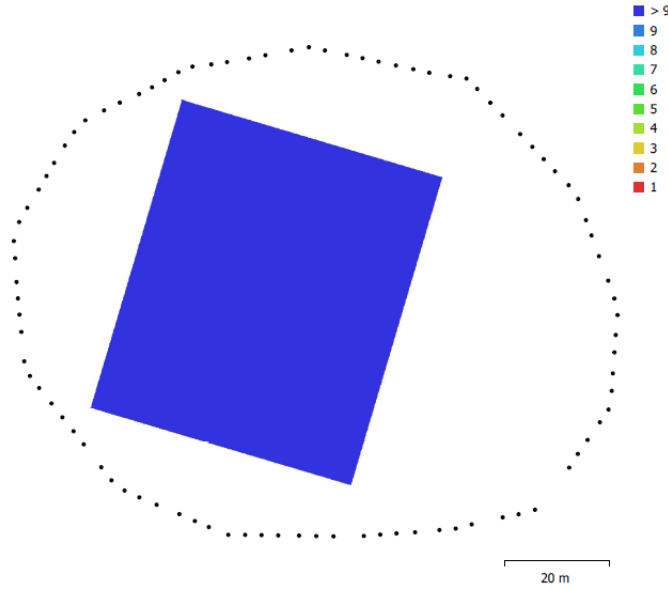
Çoklu sensörlü kameranın proje anında gerçekleştirilen kalibrasyonu sonucu distorsiyon modellenmiş ancak görüntülerde fotogrametrik görüntü koordinatları ölçmesi sonucu oluşan nokta konumlarının hataları vektörel olarak Şekil 8’de gösterilmiştir. Görüntü ölçme hataları, karşılık gelen hücrelerdeki pikseller için üç boyutlu model üretim sonucu ortaya çıkan hataların ortalama vektörlerini gösterir. Yani değerlendirme grubundaki tüm görüntüler ve hücrenin içindeki tüm pikseller arasında ortalama alınarak belirlenir. Bu hatalar büyük oranda 1 pikselden daha küçük olduğu için kabul edilebilir düzeydedir.



Şekil 8. Yuneec E10Tvx kamerasının vektörel konum hataları

2.2.3 RGB ve termal yoğun nokta bulutlarının üretimi

Fotogrametrik zorunluluklar dikkate alınarak, yüksek bindirme oranlı termal ve RGB görüntülerin kazanımı ve yönltilmesi sonucu termal ve RGB nokta bulutları üretilmiştir. SIFT görüntü eşleme algoritmasının iyi çalışabilmesi için gerçekleştirilen görüntü alımında uçuş planı büyük önem taşımaktadır. Yüksek oranda bindirmeli görüntülerden oluşan düzenli ve sık kamera konumları ile elde edilmesi istenen nesnenin tüm cephelerinin alındığı bir uçuş planı ile yüksek çözünürlüklü 3 boyutlu modelin üretilmesi kaçınılmazdır. Çalışmada, İHA'ya entegre edilen çoklu sensörlü kamera ile çekilmiş RGB görüntülerin uçuş planı Şekil 9'da gösterilmiştir.



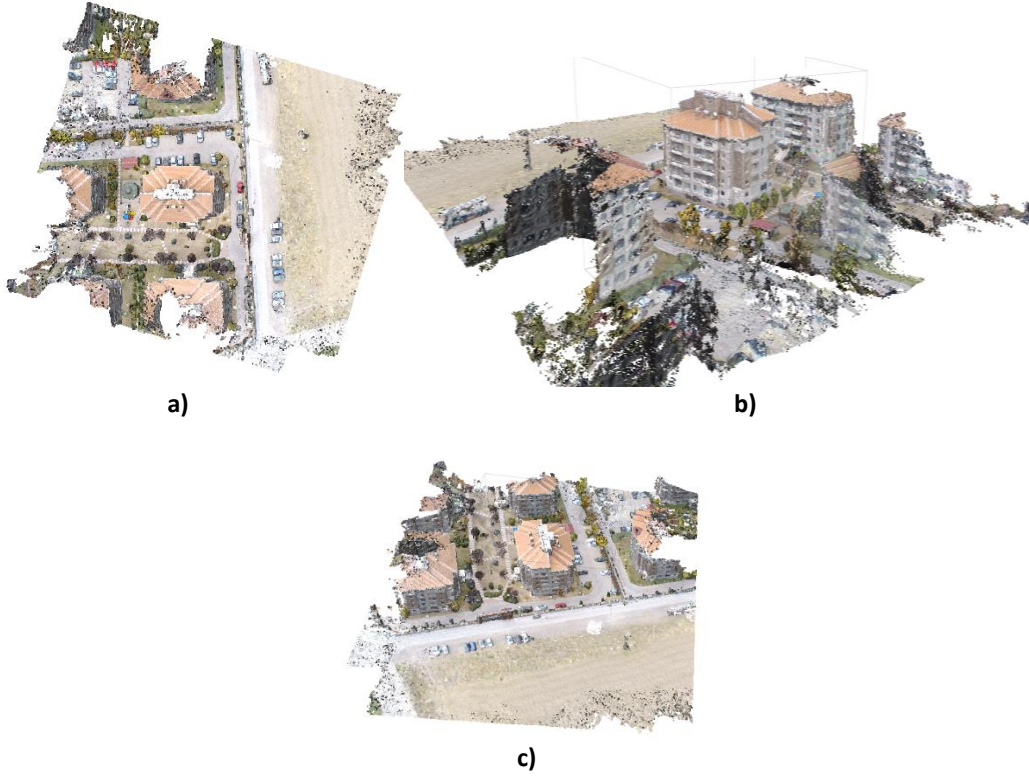
Şekil 9. Kamera konumlarının nesne üzerinde yer alan konumları

Uçuş planına dair kamera konum sayısı, uçuş yüksekliği, bağlantı noktası sayısı ve ölçek gibi birtakım bilgiler Tablo 4'te verilmiştir.

Tablo 4. Uçuş planına dair birtakım bilgiler


| | |
|-------------------------|---------|
| Kamera Konumu Sayısı | 92 |
| Uçuş Yüksekliği | 60.5 m |
| Bağlantı Noktası Sayısı | 72.853 |
| Ölçek | 280.032 |

Termografik ve metrik bilginin kombinasyonu için tek yol lazer tarama ile termograflerin füzyonu değildir. Bu yöntemin tercih edilmeyip İHA fotogrametrisi talebinin artmasının nedeni zamanın kısıtlı oluşu ve pratik olmayışındandır. Çoklu-görüş stereo (multi-view stereo) algoritması yoğun nokta bulutu üretmek için kullanılır. Bu algoritma seyrek nokta bulutu üretiminde belirlenen yöneltme parametrelerine dayalı görüntü çiftlerinin epipolar geometrisi ile yoğun nokta üretir. Fotogrametrik modelin derinlik bilgisi burada belirleyici bir kriter oluşturmaktadır. Katı modeller, sayısal arazi modelleri, sayısal yükseklik modelleri ve ortofotolar gibi ürünler yoğun nokta bulutundan üretildiği için gereklidir. RGB ve termal seyrek nokta bulutlarının çoklu stereo görüntüler ile yoğunlaştırılması ayrı fotogrametrik değerlendirmeler ile birbirinden bağımsız şekilde gerçekleştirilmiştir. Üretilen RGB yoğun nokta bulutunun çeşitli açılardan görünümü Şekil 10'da verilmiştir.



Şekil 10. a) RGB yoğun nokta bulutu önden görünüm b) RGB yoğun nokta bulutu kuzey-batı görünümü c) RGB yoğun nokta bulutu-güney-doğu görünümü


Termografik görüntülerin kayıt edilmesi ile elde edilen termografik yoğun nokta bulutu üretimi derinlik haritasından belirlenen düşük güvenilirlik noktaları filtrelenerek gerçekleştirilmiştir. Böylelikle, bakış açısı etkileri elimine edilerek termografik mozaik üretimi için gerekli olan yoğun nokta bulutu elde edilmiştir (Şekil 11).




Şekil 11. Termografik yoğun nokta bulutu

2.3 RGB-TIR Model Füzyonu

Bina yorumlama için termografinin asıl yararı, fotogrametrik ölçme ve değerlendirmenin düzenli bir izleme ve kontrol yöntemi olarak kullanılma potansiyelidir. Harcanan emeğin azalması ile yüzlerce nokta ölçme ihtiyacını da ortadan kaldırmaktadır. Termografik ve metrik bilgiyi kombine etmek için yüksek hassasiyetli birincil çözüm binanın üç boyutlu geometrik bilgisinin lazer tarama ile belirlenerek termografileri füzyon etmektir. Bu çalışmada daha düşük maliyetli geometrik modelleme RGB görüntülerden fotogrametrik model ve yüksek çözünürlüklü üç boyutlu nokta bulutu üretimi ile gerçekleştirilmiş sonra termal görüntülerle dokulandırılması hedeflenmiştir. Ancak yaklaşım birkaç hata barındırabilir. İlk olarak, termal görüntüler RGB görüntüler ile kıyaslandığında çözünürlüğü düşüktür. Termal görüntüdeki düşük çözünürlük durumunun en belirgin dezavantajı modeller arasında sağlam bir dönüşüm sağlamak için gerekli yüksek çözünürlüklü RGB görüntü arasında ortak noktaların tespit etme zorluğudur. İkinci olarak, termal görüntülerin veri kazanım süreci binanın yüzey sıcaklıkları hızlıca değiştiği için sonuçları etkilemede önemli rol oynar. Bu yüzden veri toplama süreci hızlı olmalıdır. Fakat aynı zamanda hızlı termal görüntü kazanımı doğruluğu etkileyen bulanık görüntü üretmeye eğilimlidir (Li vd., 2022). Termografik görüntülerin birleştirilmesi ile oluşturulan termografik mozaik, görüntü eşleme algoritmalarına tabi tutularak görüntü füzyonunu mümkün kılmaktadır. Böylelikle, bina ısı yalıtımının kalitesinin incelenmesi için RGB ve termal bilgiyle yüklü model analize katkı sağlar. Ayrıca termal ve RGB görüntülere dayalı oluşturulan fotogrametrik bina yüzey sıcaklık modeli, lazer tarama yöntemi ya da diğer jeodezik ölçme yöntemlerine göre hız ve maliyet açısından da önemli bir alternatif oluşturmaktadır. Sunulan yaklaşım ile düşük çözünürlüklü termal görüntülere doğrudan görüntü eşleme algoritmalarını uygulamak yerine füzyonu gerçekleştirilmiş görüntüler kullanılmaktadır. Doğru bir füzyon model için her iki modelde işaretlenen ortak noktaların mümkün olduğunca belirgin nesne unsurları olması önemlidir. Otomatik bir tespit algoritmasına dayalı olmayan bu tespit işleminin başarısı kullanıcının manuel işaretleme yeteneğine bağlıdır. RGB ve termal katı model üzerinde işaretlenen noktalar Şekil 12 ve 13’de verilmiştir.



Şekil 12. RGB katı modeli üzerinde işaretlenen nokta konumlarının gösterimi




Şekil 13. Termal katı modeli üzerinde işaretlenen nokta konumlarının gösterimi

Veri füzyonuna dair kamera parametreleri Tablo 5' te verilmiştir.

Tablo 5. Veri füzyonuna dair birtakım parametreler

| | |
|-------------------------|--------------------------------|
| Kamera Konumu Sayısı | 184 |
| Uçuş Yüksekliği | 60.5 m |
| Alan Boyutu | $3.62 \times 10^3 \text{ m}^2$ |
| Bağlantı Noktası Sayısı | 84.729 |
| Ölçek | 315.003 |

Füzyonu gerçekleştirilmiş RGB ve termal yoğun nokta bulutunun kamera konumlarının hata tahminlerine dair görsel Şekil 14' te verilmiştir.



Şekil 14. Kamera konumları ve hata tahminleri


Üç boyutlu nokta bulutunda termal ve RGB verilerin sıklığı, yoğun nokta bulutu elde edildikten sonra elde edilebilecek sayısal yükseklik modelinin kalitesini arttırmaktadır (Kršák vd., 2016). Füzyonu gerçekleştirilmiş veriden elde edilen katı modelin görselleri Şekil 15’ de verilmiştir.




Şekil 15. Füzyonu gerçekleştirilmiş katı modelin farklı açılardan gösterimi

2.3.1 RGB-TIR sayısal yükseklik modeli ve ortofoto üretimi

Fotogrametrik model ile üretilen yoğun nokta bulutlarının yükseklik boyutu kullanılarak SYM üretilmektedir. Üretilen SYM’nin yükseklik seviyelerini farklı renklendirmeler ile görselleştiren mutlak normal bakış açısından görüntüleri oluşturulabilmektedir. Ayrıca SYM, ortofoto üretimi için oldukça önemlidir. Üretilen SYM fotogrametrik yöneltme parametrelerine bağlı olarak görüntülerden alınan piksel renk değerlerinin bir düzleme projeksiyonu ile gerçekleştirilir. Ortofoto üretiminin kalitesi görüntülerin çözünürlüğü ve fotogrametrik modelin kalitesi ile doğru orantılıdır. Şekil 16, görüntü füzyonuna dayalı sayısal yükseklik modelini göstermektedir. Diğer taraftan füzyonu gerçekleştirilmiş görüntüler ile oluşturulan ortofoto Şekil 17’de verilmiştir.



Şekil 16. Füzyonu gerçekleştirilmiş sayısal yükseklik modeli (SYM)



Şekil 17. Füzyonu gerçekleştirilmiş modelin ortofotosu

2.3.2 RGB-TIR modelinin analizi

İHA'ya entegre edilen çoklu sensörlü kameraların parametreleri, bu parametreleri bilinmeyen olarak kabul eden ve tüm modelin dengelemesine katılması yöntemiyle diğer bir ifadeyle iş anında kamera kalibrasyonu ile belirlenmiştir. Fotogrametride kullanılan metrik kameraların en önemli özelliği, iç yöneltme elemanları ve kamera distorsiyon hatalarının bilinmesidir. Bir çeşit mercek kusuru olan distorsiyonlar fotoğraf üzerinde nesne konumunun değişimine neden olmaktadır. Kalibrasyon parametrelerine dair bilgiler Tablo 6'da verilmiştir. F ifadesi odak uzaklığını, K1 ve K2 radyal distorsiyon parametrelerini ve P1 ve P2 teğetsel distorsiyon parametrelerini ifade etmektedir.

Tablo 6. RGB kameranın kalibrasyon korelasyon matrisi


| | Değer | Hata | F | K1 | K2 | P1 | P2 |
|----|----------|---------|------|-------|-------|-------|-------|
| F | 1255.94 | 0.14 | 1.00 | -0.14 | 0.46 | 0.04 | -0.40 |
| K1 | -0.11010 | 0.00092 | | 1.00 | -0.81 | -0.06 | -0.19 |
| K2 | 0.09916 | 0.00011 | | | 1.00 | 0.04 | -0.13 |
| P1 | -0.00039 | 0.00002 | | | | 1.00 | 0.01 |
| P2 | 0.00016 | 0.00002 | | | | | 1.00 |

RGB sensöre oranla termal sensörün distorsiyon değerleri yüksektir. Tablo 7'de termal sensörün kalibrasyon korelasyon matrisi verilmiştir.

Tablo 7. Termal kameranın kalibrasyon korelasyon matrisi

| | Değer | Hata | F | K1 | P1 | P2 |
|----|----------|---------|------|------|-------|-------|
| F | 1132.04 | 2.40000 | 1.00 | 0.11 | -0.02 | 0.20 |
| K1 | -0.19022 | 0.00200 | | 1.00 | -0.01 | 0.25 |
| P1 | -0.00013 | 0.00028 | | | 1.00 | -0.01 |
| P2 | -0.00078 | 0.00038 | | | | 1.00 |

RGB yoğun nokta bulutunda toplam nokta sayısı 2792.968 iken termal nokta bulutunda 11.879'dur. Füzyonu gerçekleştirilmiş RGB-termal nokta bulutunun nokta sayısı 84.729'dur. Görüntü eşleme algoritmaları doğrudan termal görüntülere uygulandığında yeterli eşlenik noktası üretilmemektedir. Bu nedenle yüksek çözünürlüklü üç boyutlu RGB modelden yararlanılmıştır. Çalışma kapsamında inşa edilen RGB sayısal yükseklik modelinin çözünürlüğü 9.82 cm/piksel, termal modelin 18.43 cm/piksel iken, füzyon modelin çözünürlüğü 14.90 cm/piksel olarak belirlenmiştir. İnşa edilen RGB-Termal sayısal yükseklik modeli Şekil 18'de gösterilmiştir.




Şekil 18. İnşa edilmiş sayısal yükseklik modeli boyutları

3. Sonuçlar ve Tartışma

Çoklu sensörlü kamera ile kazanılan termal görüntülerin gün ışığında kazanılmış olması ve termal görüntülerin doğası gereği kapsama alanı dar, pürüzlü ve bulanık olması gibi nedenlerle daha düşük çözünürlüklü termal nokta bulutu elde edilmiştir. Ek olarak, RGB nokta bulutu üretim aşamasında tespit edilen bağlantı nokta sayısı 72.853 ve termal nokta bulutu bağlantı noktası sayısı 11.856 değerine odaklanıldığında azalma gözlenmiştir. Yüksek kalitede termal nokta bulutu üretiminde bahsedilen zorlukların üstesinden gelmek amacıyla RGB görüntülerden yararlanılmıştır. Metodolojide, RGB ve termal yoğun nokta bulutunda ayrı ayrı işaretlenen belirli bir konumu temsil eden noktalar sayesinde füzyon gerçekleştirilmiştir. Böylelikle, termal görüntülerin dar kapsama alanı ve farklı yükseklikten alınması nedeniyle ortaya çıkabilecek hatalar elimine edilmiştir. Güncel literatür değerlendirildiğinde Han ve Huh (2019)'dan farklı olarak bu çalışmada RGB ve termal modellerin birlikte değerlendirmesi ile model doğruluklarındaki iyileştirmeler sunulabilmiştir. Ayrıca bu çalışmada, Javadnejad vd. (2020) çalışmasından farklı olarak füzyon işleminin doğrudan üç boyutlu füzyona dayalı olarak gerçekleştirilmesi ile farklı spektrumda elde edilen görüntülerin nokta eşleşmesindeki otomatik işlem zorluğu aşılabılmıştır. Bu makalede öne çıkan diğer bir husus ise sensör yetersizliğine ve gün ışığı, İHA titreşimleri vb. dış etkilere dayalı olarak termal görüntülerin birbirleri arasında ortaya çıkan radyometrik farklılıkların iyileştirmesinin sağlanması olmuştur. Bu iyileştirme fotogrametrik ölçü kalitesini doğrudan artıran bir etki olarak gözlenmiştir.


Termal görüntülerin üzerine gün ışığı etkisinin geceye kıyasla daha fazla bozucu olduğu bilinmektedir. Buradan yola çıkılarak daha geniş kapsamlı uygulama ve analizler için gece saatlerinde yapılacak veri kazanımının doğruluğu arttıracak değerlendirilmektedir. Veri alımı gerçekleştirilecek unsurun etrafında termal alımı güçlendirebilecek ağaç, araba gibi nesnelerin miktarı ve mesafesi de dikkat edilmesi gereken diğer bir etken olarak öne çıkmaktadır. Uygulama kapsamında, özellikle çatı, balkon ve pencerelerde yalıtımsızlık sebebiyle ısı kaçakları yoğun olarak tespit edilmiştir. Termal görüntüleme malzeme türüne bağlı olarak ışın yayılımını kaydettiği için sadece yalıtıma bağlı mutlak sıcaklık değişimlerini değil aynı zamanda malzeme değişimine bağlı sıcaklık değişimlerini de verir. Ancak bu çalışmada çekim anında üretilebilen radyometrik özellikli termal bir görüntü formatı olmadığından mutlak sıcaklık değerleri elde edilememiştir. Gösterilen tüm analiz ve sonuçlar göreceli sıcaklık değişimlerine dayalı oluşturulmuştur. Mutlak sıcaklık bilgisi olmadığından makalede sunulan görseller için ayrıca sıcaklık değerlerine karşılık gelecek bir lejant oluşturulamamıştır. Bu durum, sıcaklık farklarındaki niceliksel değişimlerin ortaya konulamaması nedeni ile çalışmanın kısıtlayıcı bir etkisi olarak değerlendirilmektedir. Ancak diğer taraftan RGB görüntüye dayalı olarak homojen malzeme yüzeylerinin kendi içerisinde değerlendirmesi de önemlidir. Örneğin, binada üzerinde sabitlenmiş yağmur ve atık su tahliye boru hatları da sıcaklık farklılıkları göstermektedir. Cephelelerdeki homojen malzemelerin olduğu yüzeylerdeki sıcaklık farklılıklarının olması ise potansiyel yalıtım hatalarına işaret etmektedir. Potansiyel yalıtım hata kaynaklarının fotogrametrik inceleme dışında uzmanlar tarafından yerinden de incelenmesi önemlidir. Katlar arasında sıcaklık farkları göz önüne alındığında, ısı yalıtımının hataları sebebiyle veya harcanılan yakıt miktarı farklılıkları nedeniyle meydana gelip gelmediği tahmini yürütülebilmektedir. Şekil 19' da yoğun ısı kaçaklarının tespit edildiği bazı öne çıkan yerler belirtilmiş olup siyah daireler ile işaretlenmiştir. A bölgesi cephe malzeme yüzeyi farklılığı nedeniyle sıcaklık farkı ortaya koymaktadır.

B ve C bölgesi balkon üzerinde yer alan bölgede sıcaklık farkı göstermektedir ve bunun muhtemel sebebi o bölgedeki yalıtım eksikliğidir. Yine D bölgesinde homojen yüzey malzeme olan bölgede yer alan sıcaklık farkı potansiyel yalıtım hatasını göstermektedir. Kesin tespit için o bölgelerin yalıtım uzmanları tarafından yerinde ve yakından incelenmesi önemlidir.



Şekil 19. Termal üç boyutlu modelin güneybatı cephesi üzerinde tespit edilen bazı sıcaklık farkları

Bina ısı yalıtımının eksikliklerinin tespit edilmesine yardımcı olmak için fotogrametrik bir yaklaşım geliştirilmiştir. Sonuç olarak füzyonu gerçekleştirilmiş görüntüler, yüksek çözünürlüklü termal bilgiler ile donatılmış görünür görüntülerdir. İHA ile yüksek kaliteli üç boyutlu model üretimi sırasında uçuş planı büyük önem taşımaktadır. Görüntü alımı sık ve binanın tüm cephelerini kapsayacak şekilde gerçekleştirilmelidir. İyi bir uçuş planı oluşturulsa bile kazanılan termal görüntülerle üretilen üç boyutlu modellerde boşluklar oluşabilmektedir. Uygulama kapsamında üretilen modelin bozuk yönleri Şekil 20’de verilmiştir. Bozuklukların en önemli etkeni gün ışığının geliş yönüne bağlı olarak yansıma etkisi ortaya koyması ve buna bağlı olarak termal görüntüleme radyometrik farklılıklar oluşmasından kaynaklanmaktadır. Özellikle çatı incelendiğinde bu etki çatının iki farklı yarısında renk tonlarında oluşan farklılıklar olarak gözlenmektedir. Diğer etki ise düşük çözünürlüğe bağlı olarak çatı ve cephe üzerindeki detayların seçilmesindeki zorluklardır.



Şekil 20. Termal katı modelin bozuk yönleri

Termal görüntülerin yönlendirilmesi ve eşlenmesi zordur ancak görünür görüntüler referans alınarak bu güçlük ortadan kaldırılabilmektedir. Sonuç olarak, veri birleştirilmesi ile termal model ile belirlenen sıcaklık noktalarının RGB modeldeki karşılıklarının tespit edilebilmesi nedeni ile sıcaklık farklarının bina yüzeyindeki yerleri doğrudan anlaşılabilir. Ancak termal model ölçme noktalarının yüksek hataya sahip olduğu lokasyonlarda tutarsızlıklar kaçınılmaz olarak ortaya çıkmaktadır. Çalışma sonucunda elde edilen RGB-termal üç boyutlu model enerji iyileştirme çalışmaları, suç araştırmaları ve daha pek çok uygulama için kullanılabilir. Gelecek çalışmalarda daha yüksek çözünürlüklü bir termal kamera kullanılarak ortaya çıkan model boşluklarının giderilmesi amaçlanacaktır. Ek olarak, yer kontrol noktası tesis edilerek nokta konum hatalarının azaltılması hedeflenecektir.

Termal görüntüler güneş ışığının yansımından etkilendiği için RGB ve termal verilerin yaz, kış ve gece, gündüz olmak üzere gerçekleştirilecek veri kazanımı ile zamansal analiz aracılığıyla bozucu etkileri ortaya konulabilir.

Teşekkür

Bu çalışma Çanakkale Onsekiz Mart Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje numarası: FBA-2020-3306.

Kaynaklar

- Bayraktar, D., & Bayraktar, E. (2016). Mevcut binalarda ısı yalıtımı uygulamalarının değerlendirilmesi. *Mehmet Akif Ersoy Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 7(1), 59-66.
- Bektaş, V., Çerçevik, A. E., & Kandemir, S. Y. (2017). Binalarda ısı yalıtımının önemi ve ısı yalıtım malzemesi kalınlığının yalıtıma etkisi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 4(1), 36-42.
- Demir, N. (2011). *Yüksek yapılar ve sürdürülebilir enerji* (Yüksek Lisans Tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Durgut, A., & Akçay, Ö. (2016). Termal kamera ile ekran kartının 3 boyutlu modelinin oluşturulması. *Anadolu University Journal of Science and Technology A-Applied Sciences and Engineering*, 17(1), 51-63.
- Gade, R., & Moeslund, T. B. (2014). Thermal cameras and applications: a survey. *Machine vision and applications*, 25(1), 245-262.
- Ham, Y., & Golparvar-Fard, M. (2013). An automated vision-based method for rapid 3D energy performance modeling of existing buildings using thermal and digital imagery. *Advanced Engineering Informatics*, 27(3), 395-409.
- Han, D., & Huh, J. (2019). Thermal data fusion for building insulation. In *2019 International Conference on System Science and Engineering (ICSSE), 2019. Proceedings.* (pp. 368-371). IEEE.
- İMO. (2015). *Binalarda ısı yalıtımı ve ısı yalıtım malzemeleri*. Yapı Malzemeleri Komisyonu, Retrieved from http://www.imo.org.tr/resimler/ekutuphane/pdf/17182_44_51.pdf
- Javadnejad, F., Gillins, D. T., Parrish, C. E., & Slocum, R. K. (2020). A photogrammetric approach to fusing natural colour and thermal infrared UAS imagery in 3D point cloud generation. *International Journal of Remote Sensing*, 41(1), 211-237.
- Kim, J. B., Jeong, W., Clayton, M. J., Haberl, J. S., & Yan, W. (2015). Developing a physical BIM library for building thermal energy simulation. *Automation in construction*, 50, 16-28.
- Kršák, B., Bliščan, P., Pauliková, A., Puškárová, P., Kovanič, L. M., Palková, J., & Zelížňaková, V. (2016). Use of low-cost UAV photogrammetry to analyze the accuracy of a digital elevation model in a case study. *Measurement*, 91, 276-287.
- Kylili, A., Fokaides, P. A., Christou, P., & Kalogirou, S. A. (2014). Infrared thermography (IRT) applications for building diagnostics: A review. *Applied Energy*, 134, 531-549.
- Lagüela, S., Armesto, J., Arias, P., & Herráez, J. (2012). Automation of thermographic 3D modelling through image fusion and image matching techniques. *Automation in Construction*, 27, 24-31.
- Li, Q., Cao, R., Zhu, J., Hou, X., Liu, J., Jia, S., & Qiu, G. (2022). Improving synthetic 3D model-aided indoor image localization via domain adaptation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 183, 66-78.
- Nex, F., & Remondino, F. (2014). UAV for 3D mapping applications: a review. *Applied Geomatics*, 6(1), 1-15.
- Rakha, T., & Gorodetsky, A. (2018). Review of Unmanned Aerial System (UAS) applications in the built environment: Towards automated building inspection procedures using drones. *Automation in Construction*, 93, 252-264.
- Sledz, A., Unger, J., & Heipke, C. (2018). Thermal IR imaging: Image quality and orthophoto generation. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(1), 413-420.
- Snavely, N., Seitz, S. M., & Szeliski, R. (2006). Photo tourism: exploring photo collections in 3D. *ACM Transactions on Graphics*, 25(3), 835-846.
- Su, M., Ma, Y., Zhang, X., Wang, Y., & Zhang, Y. (2017). MBR-SIFT: A mirror reflected invariant feature descriptor using a binary representation for image matching. *PLoS One*, 12(5), e0178090. doi: 10.1371/journal.pone.0178090.
- Tarık, T., & Öcalan, T. (2020). PPK GNSS Sistemine Sahip İnsansız Hava Araçları ile Elde Edilen Fotogrametrik Ürünlerin Doğruluğunun Farklı Yaklaşımlarla İrdelenmesi. *Türkiye Fotogrametri Dergisi*, 2(1), 22-28.
- TSE. (2013). *TS 825 Binalarda Isı Yalıtım Kuralları*. Retrieved from http://www1.mmo.org.tr/resimler/dosya_ekler/cf3e258fbdf3eb7_ek.pdf

Eskişehir Kent Merkezindeki Trafik Kazalarının Zamana Bağlı Konumsal Analizi

Spatiotemporal Analysis of Traffic Accidents in Eskişehir City Center

Vural Yıldırım¹, Erdem Yurdakul¹, Gökben Adana Karaağaç^{1*}, Merve Koçer¹,
Hakan Uyguçgil²

¹Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri ABD, 26555, Eskişehir/Türkiye.

²Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Jeodezi ve Coğrafi Bilgi Teknolojileri ABD, 26555, Eskişehir/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Gökben Adana Karaağaç
gokbenkaraagac@gmail.com

doi: 10.48123/rsgis.1167844

Yayın süreci

Geliş tarihi: 28.08.2022

Kabul tarihi: 20.02.2023

Basım tarihi: 28.03.2023

Özet

Trafik kazalarının önlenmesinde ilk yapılması gereken işlem kazaların yoğunlaştığı noktaların belirlenmesidir. Bu amaçla 2010-2019 yılları arasında Eskişehir kent merkezinde meydana gelen trafik kazaları istatistiksel olarak benzer, yaklaşım olarak farklı iki yöntem kullanılarak analiz edilmiştir. Çalışmada önce klasik sıcak nokta analizi kullanılmış ve 15 sıcak nokta tespit edilmiştir. Daha sonra aynı veri seti konum-zaman küpü kullanılarak zamana bağlı sıcak nokta yöntemi ile analiz edilmiş, 50 aralıklı, 10 yeni, 7 ardışık, 4 sürekli, 1 azalan ve 1 yoğunlaşan olmak üzere toplam 73 sıcak nokta bulunmuştur. İki yöntemin sonuçları kıyaslandığında, zamana bağlı sıcak nokta analizi ile 1. bölgedeki sıcak nokta sayısının 6'dan 19'a, 2. bölgedeki sıcak nokta sayısının 2'den 20'ye, 3. bölgedeki sıcak nokta sayısının 3'den 12'ye, 4. bölgedeki sıcak nokta sayısının 3'den 11'e ve 5. bölgedeki sıcak nokta sayısının 1'den 11'e çıktığı görülmüştür. Klasik sıcak nokta analizine kıyasla zamana bağlı sıcak nokta analizi ile farklı konumlarda ve farklı desenlerde daha çok trafik kazası sıcak noktalarının tespit edilmesi, konumun ve zamanın bir arada kullanılmasının önemini ortaya koymaktadır. Çalışma sonucunda zamana bağlı sıcak nokta analizinin klasik sıcak nokta analizine göre daha detaylı sonuçlar verdiği gözlemlenmiştir.

Anahtar kelimeler: Coğrafi Bilgi Sistemleri, Trafik kazaları, Konum-zaman küpü yöntemi, Klasik sıcak nokta analizi, Zamana bağlı sıcak nokta analizi

Abstract

The first thing to do in preventing traffic accidents is to determine the spots where the accidents are concentrated. For this purpose, traffic accidents in Eskişehir city center that occurred between 2010-2019 were analyzed using two methodologies those are statistically similar but different in approaches. Firstly, classical hot spot analysis was performed, and 15 hot spots were found. Subsequently, the same data set was analyzed with the emerging hot spot using the space-time cube method, and a total of 73 hot spots were detected, including 50 sporadic, 10 new, 7 consecutive, 4 persistent, 1 diminishing, and 1 intensifying. A comparison of the results of the two methodologies shows an increase in the number of hot spots in the first region from 6 to 19, in the second region from 2 to 20, in the third region from 3 to 12, in the fourth region from 3 to 11 and in the fifth region from 1 to 11. Finding more hot spots in different locations and patterns with emerging hot spot analysis proportional to classical hot spot analysis reveals the importance of using location and time together. As a result of the study, it was observed that the emerging hot spot analysis provides more detailed outcomes whence the classical hot spot analysis.

Keywords: Geographic Information Systems, Traffic accidents, Space-time cube method, Classical hot spot analysis, Emerging hot spot analysis

1. Giriş

Can ve mal kayıpları ile sonuçlanan trafik kazaları, ülkemizde ve dünyada günden güne daha büyük bir problem haline gelmektedir. Bunun en büyük nedenlerinden biri, artan nüfus ve buna bağlı olarak artan araç sayısıdır. Trafik kazalarının nedenlerinin ya da daha çok hangi bölgelerde yoğunlaştığının tespit edilmesi ve bunlara çözümler üretilmesi, kamu sağlığı ve güvenliği açısından önemli bir konudur. Dünya Sağlık Örgütü (World Health Organization - WHO) istatistiklerine göre; her yıl 1,3 milyon insan trafik kazaları nedeniyle hayatını kaybetmektedir. Bu kazaların maliyeti, çoğu ülkenin gayrisafi yurtiçi hasılasının yaklaşık %3'ünü oluşturmaktadır. Kazaların yarısından fazlası yayaların, bisikletlilerin ve motosiklet sürücülerinin hayatlarını kaybetmeleriyle sonuçlanmakta ve ölümlerle sonuçlanan kazalar daha çok düşük ve orta gelirli ülkelerde meydana gelmektedir (WHO, 2022). Karayolları Genel Müdürlüğü 2021 yılı trafik kazaları özetine göre, Türkiye'de 2021 yılında yaklaşık 1,2 milyon trafik kazası gerçekleşmiştir. Bu kazaların yaklaşık 188 bini ölümlü veya yaralanmalı olarak kayıtlara geçmiştir (TCK, 2021). Dünya Sağlık Örgütü ve Türkiye Karayolları Genel Müdürlüğü'nün istatistiklerine bakıldığında; trafik kazalarına hangi faktörlerin neden olduğunun tespit edilmesi, bu kazaları azaltıcı ya da önleyici tedbirler alınması, kazaların hangi noktalarda ya da bölgelerde yoğunlaştığının bilinmesi gerekliliğinin önemi ortaya çıkmaktadır.

Şehirleşmeye ve ticari alanlardaki değişimlere bağlı olarak kentlerin trafik yoğunlukları değişim göstermekte ve trafik kazaları kentlerin önemli bir problemi haline gelmektedir. Bu problemin çözümünde en kritik konulardan biri, kazaların yoğunlaştığı bölgelerin tespit edilip, gerekli tedbirlerin alınmasıdır. Literatürde konuyla ilgili çalışmalarda, kazalar genellikle belirli bir yıl gibi zaman kesitini kapsamaktadır. Tek bir yıl veya zaman kesiti ile çalışmak çok fazla açıklayıcı bilgi vermemektedir. Bu nedenle, trafik kazalarının zamana bağlı olarak analiz edilmesi daha sağlıklı sonuçlar vermektedir.

Özellikle ölüm ve yaralanmalarla sonuçlanan trafik kazalarını azaltmak ya da engellemek ve trafik ve yol güvenliğini artırmak için politika yapıcılara karar verme süreçlerinde yardımcı olacak bilimsel yöntemler geliştirilmiştir (Uğur Özçelik vd., 2013). Bu yöntemlerden bazıları trafik kazalarını etkileyen sürücü yaşı, sürücü cinsiyeti, yol genişliği, aydınlatma, hava durumu gibi faktörleri incelerken; bazıları kazaların yoğunlaştığı noktaları ya da bölgeleri inceleyen yöntemlerdir. Trafik kazaları, gerçekleştikleri coğrafi alanda yoğunlukla kümelenme eğilimi göstermektedir (Xie ve Yan, 2008). Trafik kazalarının yoğunlaştığı bölgelerin tespitinde sıklıkla kullanılan yöntemlerden biri sıcak nokta analizidir. Sıcak nokta analizi, yerel ölçekte gerçekleşen olayların yoğunluğunu ve kümelenmesini gösteren, tanımlanabilir bir sınır içerisindeki konumu veya küçük bir alanı belirlemeye yardımcı olan analizdir (Ord ve Getis, 1995). Ayrıca, trafik kazalarının sıcak noktalarının belirlenmesi trafik güvenliği stratejilerinin oluşturulması (Moons vd., 2009) ve güvenlik iyileştirmeleri kapsamında kaynakların uygun şekilde kullanılabilmesi için kilit bir konu olarak görülmektedir (Anderson, 2009).

Bu çalışmada, Eskişehir ili kent merkezinde 2010-2019 yılları arasında gerçekleşen trafik kazalarının zamana bağlı konumsal analizinin, konum-zaman küpü yöntemi ile gerçekleştirilen zamana bağlı sıcak nokta analizi ile incelenmesi ve aynı veri seti üzerinden zamandan bağımsız olan sıcak nokta analizi ile sonuçlarının karşılaştırılması amaçlanmıştır. Çalışmanın amacına bağlı olarak literatür özeti, sıcak nokta analizi ve zamana bağlı sıcak nokta analizi ile trafik kazalarını inceleyen çalışmalar kapsamında ele alınmıştır.

2008-2013 yılları arasında Kahramanmaraş şehir merkezinde trafik kazalarının yoğunlaştığı bölgelerin tespit edilerek, alınması gereken tedbirler ile ilgili önerilerin sunulması (Özmal vd., 2014); Etiyopya'nın Bahir Dar ile Gondar kasabası arasındaki yolda 2008-2011 yılları arasında gerçekleşen 460 trafik kazası verisi kullanılarak, kazaların sıcak noktalarının tespit edilmesi (Yohannes ve Minale, 2015); Sri Lanka'nın Galle kentinde meydana gelen trafik kazalarının sıcak noktalarının tespit edilip, kazalara etki eden faktörlerin ortaya konması (De Silva vd., 2018); Etiyopya'nın Hosanna ilçesinde 2015-2017 yılları arasında gerçekleşen trafik kazalarının sıcak noktalarının tespit edilerek, can ve mal kaybının önlenmesinin amaçlanması (Hayidso vd., 2019); Çekya'da 2010-2018 yılları arasında gerçekleşen 55.296 adet kaza verisi kullanılarak, ana yolların kırsal kesimlerinde meydana gelen kazaların sıcak noktalarının tespit edilmesi (Bil vd., 2019); 2013-2018 yılları arasında illere göre Türkiye'deki trafik kaza oranlarının konum-zaman ilişkisini dikkate alarak, kazaların mekansal dağılımının betimlenmesi ve modellenmesi (Yıldırım ve Mert Kantar, 2020); trafik kazalarının sıcak noktalarını belirlemede kullanılan yöntemlerin performanslarının karşılaştırılması (Amiri vd., 2021); Etiyopya'nın Oromia bölgesinde 2014-2017 yılları arasındaki trafik kazalarının sıcak noktalarının belirlenmesi (Tola vd., 2021); Nijerya'nın Lokoja-Abuja-Kaduna karayolunda 2013-2017 yılları arasında gerçekleşen kaza verileri kullanılarak yüksek riskli konumların yani sıcak noktaların belirlenmesi (Afolayan vd., 2022) gibi çalışmalarda trafik kazaları sıcak nokta analizi ile incelenmiştir.

Literatürde konum-zaman küpü yöntemi ile trafik kazalarını açıklayan bazı çalışmalar bulunmaktadır. 2001-2013 yılları arasında Batı Avustralya'da gerçekleşen mafsallı ağır vasıta kazalarının yoğunluğunun ve sıcak noktalarının tespiti (Gudes vd., 2017); 2012-2015 yılları arasında Seul'de meydana gelen trafik kazalarının şiddetini etkileyen faktörlerin analizi ve bu kazaların konum-zaman özelliklerinin görselleştirilmesi (Kang vd., 2017); Seul'de yaşlı nüfusun karıştığı trafik kazalarının konumsal özelliklerinin zamana göre nasıl değiştiğinin incelenmesi (Kang vd., 2018); Çin'in Wujiang şehrinde 2016 yılında yol kavşaklarında meydana gelen trafik kazalarının sıcak noktalarının belirlenmesi (Cheng vd., 2018); Çin'in Şenzen şehrinin Huaifu alt bölgesindeki yüksek riskli çarpışma noktalarının bulunması ve bu çarpışmaların konum-zaman

desenlerinin elde edilmesi (Wu vd., 2021); Ürdün'ün İrbid şehrinde 2015-2019 yılları arasında meydana gelen trafik kazalarının konum-zaman desenlerinin araştırılması (Hazaymeh vd., 2022); Kore'de ölümle sonuçlanan trafik kazası verileri ile artan ve azalan eğilimler yardımıyla kaza sıcak noktalarının belirlenmesi (Tamakloe ve Park, 2022) gibi çalışmalar trafik kazalarının konum-zaman küpü ile analiz edildiği çalışmalara örnek olarak gösterilebilir. Konum-zaman küpü ile sadece araçların karıştığı kazalar değil, yaya kaynaklı trafik kazalarının meydana gelme nedenlerini ve ciddiyetini araştıran çalışmalar da bulunmaktadır (Yoon ve Lee, 2022).

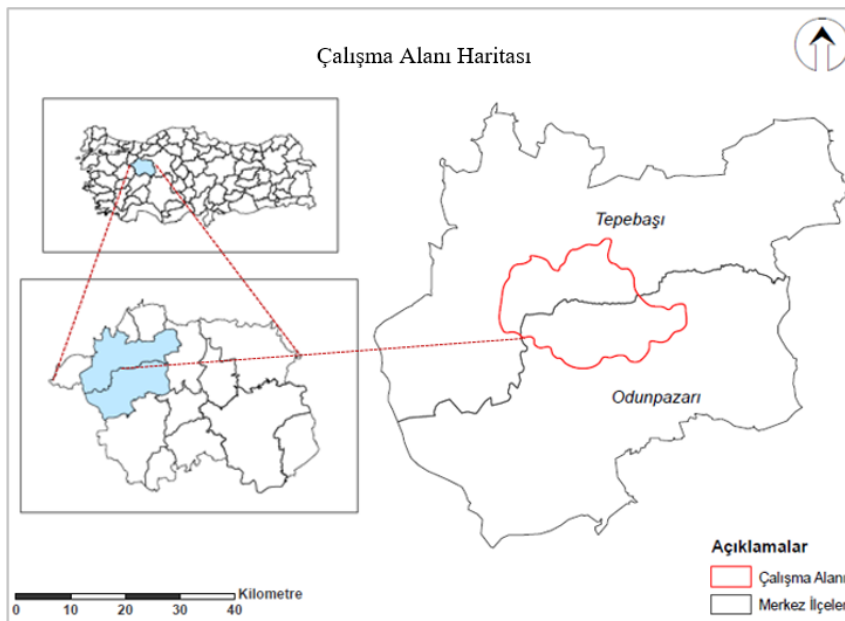
Konu ile ilgili literatüre bakıldığında trafik kazalarının sıcak noktalarını tespit etmede zaman faktörünün dikkate alınmadığı çalışmaların çoğunlukta olduğu, zaman faktörünü dikkate alan çalışmaların çok fazla olmadığı, zamanı dikkate alan çalışmaların ise büyük bir bölümünün 10 yıl gibi uzun bir zaman dilimini kapsamadığı görülmüştür. Yapılan çalışmada 10 yıllık zaman diliminin kullanılması ve klasik sıcak nokta ve zamana bağlı sıcak nokta analizinin karşılaştırılarak sonuçların yorumlanması çalışmanın özgün değerini ortaya koymaktadır. Bu çalışmada diğer çalışmalardan farklı olarak çok daha küçük bir alanda çalışılmış, sokak ölçeğine kadar inilerek daha fazla ayrıntıya değinilerek, kent merkezinde önlem alınması gereken noktalar açıkça vurgulanmıştır. Çalışma çıktıların, şehir içi yol güvenliğinin sağlanması ve mal ve can kayıplarının azaltılması ya da önüne geçilmesi gibi konularda katkı sağlayacağı düşünülmektedir. Çalışmanın ikinci bölümünde materyal ve yöntem açıklanmıştır. Üçüncü bölümde bulgular ortaya konmuş; dördüncü bölümde sonuçlara ve tartışmalara yer verilerek çalışma sonlandırılmıştır.

2. Materyal ve Yöntem

Karayolunda gerçekleşen trafik kazalarının yoğunluğunu belirlemede farklı istatistiksel yöntemler kullanılmaktadır. Araştırmacılar tarafından geliştirilen konumsal istatistik yöntemleri ile trafik kazalarının sıcak noktalarının belirlenmesinin doğruluğu artırılarak, görsel olarak sunumu zenginleştirilmiştir (Thomas, 1995). Bu bölümde, çalışma alanı ve çalışmadaki analizlerin gerçekleştirilmesinde kullanılan materyal ve yöntemler açıklanmıştır.

2.1. Çalışma Alanı


Eskişehir ili Tepebaşı ve Odunpazarı merkez ilçeler olmak üzere toplam 14 ilçeden oluşmaktadır (Şekil 1). Bu 2 merkez ilçenin yüzölçümü yaklaşık 2.500 kilometrekare olup, kentin toplam yüzölçümünün %18'ini oluşturmaktadır. 2019 yılı Adrese Dayalı Nüfus Kayıt Sistemi sonuçlarına göre Eskişehir'in nüfusu 887.475'tir (TÜİK, 2022). Tepebaşı ve Odunpazarı ilçelerinin nüfusu sırasıyla 370.150 ve 413.461'dir. Merkez ilçelerin nüfusunun, toplam nüfus içerisindeki payı %88,3'tür. Nüfusa bağlı olarak kent merkezindeki araç sayısı ve araç kullanım oranı diğer ilçelere göre oldukça yüksektir. Çalışmanın materyal bölümünde ayrıntılı şekilde anlatılan kaza verileri incelendiğinde, kaza noktalarının daha çok kent merkezinde yoğunlaştığı, diğer ilçelerde ve kırsalda bir analiz gerçekleştirecek kadar kaza verisi olmadığı görülmüştür. Bu nedenle Şekil 1'de gösterilen Eskişehir'in merkez ilçelerinde trafik kazalarının yoğunlaştığı bölge çalışma alanı olarak seçilmiştir.



Şekil 1. Çalışma alanı


2.2. Materyal

Çalışmada, 2010-2019 yılları arasında Eskişehir kent merkezinde gerçekleşen trafik kaza verileri kullanılmıştır. Söz konusu yıllara ait kaza verileri, Eskişehir İl Emniyet Müdürlüğü'nün kaza tutanaklarından oluşturmuş olduğu ve kazaların konum ve zaman bilgisini içeren veri setinden elde edilmiştir. Veri seti içerisinde zaman veya konum bilgisi olmayan kazalar analize dahil edilememiştir. Kaza noktaları incelendiğinde, yollardan sapmalar olduğu görülmüştür. Bunun nedeninin kaza anında araçların yolun dışına savrulmuş olma olasılıkları olduğu düşünülmektedir. Ayrıca, kaza noktalarının yanlış tespiti veya kayıt hataları da kaza noktalarının yoldan sapmasına neden olabilmektedir. Bu olasılıkları ortadan kaldırmak için yol dışında kalan kazalar yollarla ilişkilendirilmiştir. Yollarla ilişkilendirilemeyen kazalar çalışmaya dahil edilmemiştir. Veri düzenleme işlemleri sonunda, çalışma kapsamında kullanılacak toplam 27.562 adet kaza noktası elde edilmiş ve analize dahil edilmiştir. Şekil 2'de 2010-2019 yılları arasında Eskişehir kent merkezinde gerçekleşen trafik kazalarının yıllara göre dağılımı verilmiştir.



Şekil 2. Yıllara göre trafik kazası sayıları

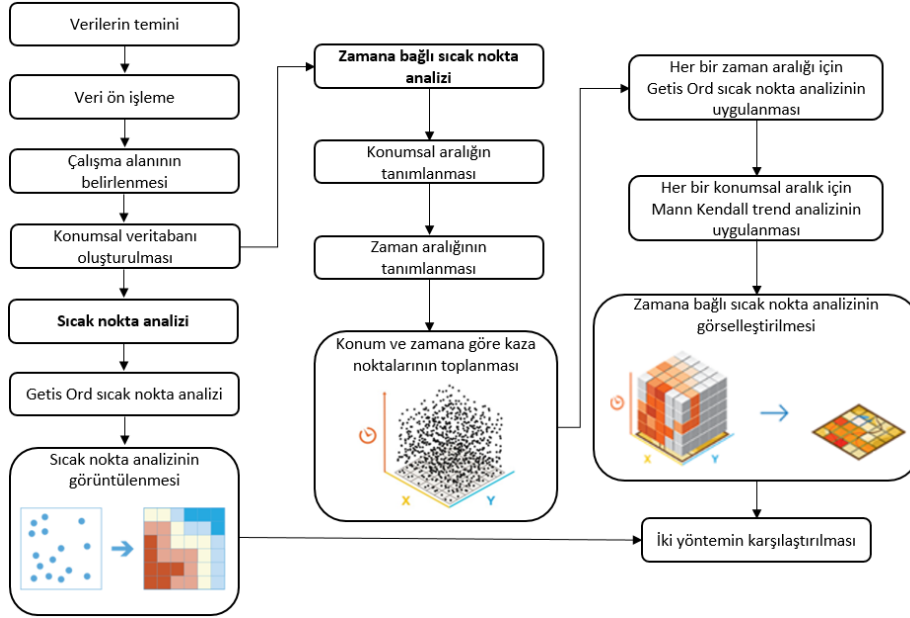
Eskişehir kent merkezinde; 2010 yılında 2.384, 2011 yılında 2.765, 2012 yılında 2.928, 2013 yılında 2.902, 2014 yılında 2.883, 2015 yılında 2.432, 2016 yılında 2.277, 2017 yılında 2.779, 2018 yılında 3.225 ve 2019 yılında 2.987 adet olmak üzere toplam 27.562 adet kaza meydana gelmiştir. 2010-2019 yılları arasında çalışma alanı içerisinde gerçekleşen tüm trafik kazalarının dağılımı Şekil 3'deki gibidir.



Şekil 3. 2010-2019 yılları arasındaki Eskişehir kent merkezinde gerçekleşen kaza yerleri

2.3. Yöntem

Çalışma kapsamında Eskişehir kent merkezinde 2010-2019 yılları arasında gerçekleşen trafik kazalarının analizi, klasik sıcak nokta ve konum-zaman küpü yöntemi ile zamana bağlı konumsal desenleri tespit etmeye yarayan zamana bağlı sıcak nokta analizi ile incelenmiştir. Çalışma kapsamında yapılan analizlerin adımları Şekil 4’de verilmiştir.



Şekil 4. Çalışmanın yöntem akış şeması

Çalışmada klasik sıcak nokta ve zamana bağlı sıcak nokta analizlerinin gerçekleştirilip sonuçlarının karşılaştırılması aşamasına kadar yapılan işlemler, Eskişehir Emniyet Genel Müdürlüğünden kaza verilerinin elde edilmesi ile başlamıştır. 2010-2019 yılları arasında Eskişehir kent merkezinde gerçekleşen trafik kaza verileri, kurumdan Access ve Excel formatında temin edilmiştir. Veri ön işleme aşamasında veri seti .csv (comma seperated values-virgülle ayrılmış değerler) formatına dönüştürülerek, veri alanlarındaki veri tipleri belirlenmiştir. Kazaların enlem ve boylam değerlerini içeren .csv uzantılı metin dosyası WGS 84/UTM zone 36N projeksiyon sisteminde nokta veri olarak yazılıma girilmiş ve konumsal veri setine dönüştürülmüştür.

Emniyet Genel Müdürlüğünden Eskişehir’in merkez ilçeleri olan Tepebaşı ve Odunpazarı’na ait kaza verileri temin edildiğinden, kent merkezine düşen kazaları belirlemek için konuma dayalı sorgulama yapılmıştır. Yapılan sorgulama sonucunda anlamsız kaza noktaları veri setinden çıkarılmış, yeni bir veri seti elde edilip dosya konumsal veritabanına (file geodatabases) kaydedilmiştir. Çalışma alanının sınırları, analiz gerçekleştirilecek yapıda ve sayıda veri olan kaza noktalarının yoğunlaştığı kent merkezi olarak belirlenmiştir. Tüm bu veri ön işleme adımlarından sonra veriler analize hazır hale getirilmiştir.

Analize hazır veri seti üzerinden zamana bağlı sıcak nokta analizi gerçekleştirilebilmek için öncelikle konumsal aralıklar (mesafe) 50 metre ve zamansal aralıklar 1 yıl olarak tanımlanmıştır. Kaza noktaları konum ve zamana göre grid yapıdaki küpler içerisine toplanmıştır. Kaza noktaları konum ve zamana bağlı olarak çalışmanın görselleştirilmesinde tercih edilen altıgenler ile birleştirilerek netCDF dosyaları oluşturulmuştur. NetCDF dosyası üzerinden her bir yıl (yatay kesit) için Getis Ord sıcak nokta analizi, her bir konum (dikey kesit) için Mann-Kendall trend analizi yapılmıştır. Trend analizinde anlamlı çıkan altıgenler Tablo 2’ye göre sınıflandırılarak, 2 boyutlu altıgenler ile görselleştirilmiştir. Ardından aynı veri seti üzerinden zamanı dikkate almayan klasik sıcak nokta analizi gerçekleştirilmiş ve Getis Ord G_i^* istatistiği hesaplanmıştır. Yatay kesitte yani her bir yıl için yapılan analiz sonuçları ise 3 boyutlu olarak görselleştirilmiştir. Son olarak yapılan 2 analizin sonuçları karşılaştırılmıştır.

2.3.1. Getis-Ord G_i^* İstatistiği

Getis-Ord G_i^* istatistiği istatistiksel olarak anlamlı olan sıcak ve soğuk noktaların tanımlanmasında kullanılan bir yöntemdir. Burada bahsi geçen *sıcak nokta*, komşularına göre istatistiksel olarak anlamlı olan yüksek değerlerin konumsal kümelenmesini; *soğuk nokta* ise komşularına göre istatistiksel olarak anlamlı olan düşük değerlerin konumsal kümelenmesini ifade etmektedir.

Getis-Ord G_i^* istatistiği, 1992 yılında Getis ve Ord tarafından uzaklığı kullanarak konumsal ilişkiyi analiz etmek amacıyla geliştirilmiştir. Bu istatistikte satır standartlaştırılmış ağırlık matrisinin hiçbir etkisi yoktur. Sonuçlar standartlaştırılmamış ağırlık matrisinin kullanılmasıyla benzerlik göstermektedir. Bu yöntem kullanılırken sabit uzaklık (fixed distance band) kullanılması önerilmektedir (Getis ve Ord, 1992). Getis-Ord lokal istatistiği Eşitlik 1'deki gibi ifade edilir:

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

eşitlikteki x_j değişkenin j . bölgedeki değeri; w_{ij} i ve j bölgeleri arasındaki konumsal ağırlık; n , toplam birim sayısına eşittir ve Eşitlik 2'deki şekilde hesaplanır:

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

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

G_i^* istatistiğinin anlamlılık sınavında, z-puanları ve p-değerleri kullanılır. Analiz sonucunda verilen z-puanları ve p-değerleri, yüksek veya düşük değerlere sahip özelliklerin konumsal olarak nerelerde kümelendiğini gösterir. Söz konusu istatistiği kullanarak sonuçlar üreten sıcak nokta analizinde komşuluk ilişkileri dikkate alınır. Yani bir noktanın istatistiksel olarak anlamlı bir sıcak nokta olabilmesi için hem kendi değerinin yüksek olması hem de yüksek değerli noktalar ile çevrili olması gerekir. G_i^* istatistiği komşu özellikler bağlamındaki her bir noktayı hesaplamaya dahil eder ve z-puanı, p-değeri ve güven seviyesi ile yeni bir özellik sınıfı oluşturulmasını sağlar.

Yüksek z puanına ve küçük p değerine sahip özellikler, istatistiksel olarak önemli sıcak nokta; düşük negatif z puanına ve küçük p değerine sahip özellikler istatistiksel olarak önemli soğuk noktalar anlamına gelir. G_i^* istatistiğinin farklı güven düzeylerinde sonuçlar vermesi, hangi sıcak noktanın diğerlerine göre daha etkin olduğu konusunda çıktılar sağlar (Li vd. 2017). Sıcak nokta analizinin farklı güven düzeylerinde verdiği sonuçlar yapılan çalışma kapsamında yorumlandığında; %99 güven düzeyindeki bir sıcak noktanın, %95 ve %90 güven düzeyindeki bir sıcak noktaya göre trafik kazaları açısından daha riskli bir yer olduğu anlamına gelmektedir. Tablo 1'de farklı güven düzeyleri için kritik p-değerleri ve z-puanları verilmiştir.

Tablo 1. G_i^* istatistiği güven düzeyleri, p-değerleri ve z-puanları

| Güven düzeyi | p-değerleri | z-puanları |
|--------------|-------------|-----------------------|
| %90 | < 0.10 | < -1.65 ya da > +1.65 |
| %95 | < 0.05 | < -1.96 ya da > +1.96 |
| %99 | < 0.01 | < -2.58 ya da > +2.58 |

2.3.2. Mann-Kendall Trend Analizi

Trend (eğilim) analizi değerlerin istatistiksel olarak zaman içerisindeki anlamlı olan genel artış veya azalışlarını ifade etmektedir. Mann-Kendall trend analizini kullanarak zamansal değişimi inceleyen zamana bağlı sıcak nokta analizinin orijinal adı "Emerging hot spot analysis" dir. Emerging kelime olarak "ortaya çıkan, beliren, öne çıkan..." anlamlarına gelmesine rağmen, analizin özüne ve sonuç olarak verdiği desenlere bakıldığında yeni, tarihi, aralıklı, sürekli, azalan gibi zamansal kavramlarla ilgili olduğu görülmektedir. Bu nedenle çalışmada analizin adı "zamana bağlı sıcak nokta analizi" olarak kullanılmıştır. Zamana bağlı sıcak nokta analizinde zamansal değişimi incelemede Mann-Kendall trend analizi kullanılmaktadır. Getis-Ord G_i^* istatistiği ve Mann-Kendall trend analizinin kullanıldığı bu yöntemde sıcak noktalar, zamana bağlı gösterdikleri eğilime göre kategorize edilebilmektedir.

Mann-Kendall trend analizi parametrik olmayan bir sıra korelasyon testidir. Çok fazla varsayıma dayanmadığından, kolayca hesaplanabilmektedir. Zaman dilimlerini kıyaslayarak gerçekleştirilen analizde; ilk zaman dilimi ikincisinden küçükse +1, ilk zaman dilimi ikincisinden büyükse -1 ve iki zaman dilimi birbirine eşitse 0 değerini alır. Burada 0 eğilimin olmadığını, +1 pozitif ya da artan bir eğilimi -1 ise negatif veya azalan bir eğilimi ifade eder. Tüm zaman dilimleri için bu hesaplamalar yapılır. Mann-Kendall test istatistiği Eşitlik 3'teki denklem ile ifade edilir:

$$S = \sum_{i=1}^{n-1} \sum_{j=k+1}^n \text{sign}(x_j - x_i) \quad (3)$$

Denklemdaki *sign* işaret fonksiyonudur ve -1, 0 ve +1 değerlerini almaktadır. *n*, toplam birim sayısına eşittir. Toplamda *S* pozitif çıkarsa, zaman içinde artan bir eğilimi; negatif çıkarsa da azalan bir eğilimi ifade etmektedir. Eğilimin anlamlı olup olmadığına ise *z* testi ile karar verilir.

2.3.3. Konum-Zaman Küpü Yöntemi ve Zamana Bağlı Sıcak Nokta Analizi


Klasik istatistiksel teknikler, bir değişkendeki verilerin birbirinden bağımsız olması varsayımına dayanır. Tobler (1970) tarafından coğrafyanın ilk kuralı: “Her şey her şeyle ilişkilidir fakat yakın olanlar uzak olanlara göre daha çok ilişkilidir.” şeklinde tanımlanmıştır. Bu kurala göre ilişkiler açıklanırken uzaklık baz alınmaktaydı. Günümüzde ise uzaklığın yanında zaman da önemli bir etken olarak ön plana çıkmaktadır. Bu nedenle Tobler’in ifadesindeki yakınlık kavramına zamanı da eklemek daha doğru bir yaklaşım olacaktır. Bu durumda Tobler’in sözü: “Her şey her şeyle ilişkilidir fakat yakın ve yeni olanlar uzak ve geçmiş olanlara göre daha çok ilişkilidir” şeklinde ifade edilebilir. Bu ilişkiler yakın zamana kadar konumsal ve zamana bağlı olarak ayrı ayrı incelenmekteydi. Coğrafi bilgi sistemleri ve istatistiksel yazılımların gelişmesiyle birlikte yapılan teorik çalışmalarda, artık konum ve zaman birlikte incelenmeye başlanmıştır.

Klasik sıcak nokta analizinde veriler zamandan bağımsız olarak sadece konumsal şekilde incelenmektedir. Zamana bağlı sıcak nokta analizinde ise veriler konumsal ilişkinin yanında zamansal değişimin de dikkate alınmasıyla sıcak veya soğuk noktaların tespit edilmesinde kullanılan bir yöntemdir.

Konum-zaman küpü yöntemi ile sıcak ve soğuk noktalar eğilim yardımıyla analiz edilebilmektedir. Yöntemdeki sıcak ve soğuk nokta analizleri Getis-Ord G_i^* , eğilim analizinde Mann-Kendall istatistiklerini kullanan zamana bağlı sıcak nokta analizi ile gerçekleştirilmektedir. Konum-zaman küpü yöntemi ile oluşturulan küpler, konum ve zaman bilgisi içeren verinin zaman serisi analizlerinde, konuma bağlı zamansal desen analizinde ve 2 ve 3 boyutlu görselleştirmesinde kullanılmaktadır (ESRI, 2022a).


Analizde kullanılan veri seti noktalardan oluşuyorsa, çalışma alanı belirlenen uzaklıklara bağlı olarak kare balık ağı veya altıgen şeklindeki grid yapıdaki küplere (grid cubes) ayrılır. Bu sayede veri hem uzaklık bakımından hem de zaman bakımından küplerle ifade edilmiş olur. Çalışma alanında konum-zaman küplerinin oluşturulabilmesi için en az 10 zaman dilimi kullanılmalıdır. Bu zaman dilimleri; saniye, dakika, saat, gün, hafta, ay, mevsim, yıl, 5 ya da 10 yıllık şekilde yapılandırılabilir. Veri küplerle ifade edildikten sonra zamana bağlı sıcak nokta analizi için bu küplere istatistiksel yöntemler uygulanır. İki aşamadan oluşan istatistiksel yöntemlerde ilk olarak aynı zaman dilimlerinde (yani yatay eksende) Getis-Ord G_i^* ile sıcak noktalar hesaplanır. İkinci aşamada tüm zaman dilimleri arasında (yani dikey eksende) Mann-Kendall ile eğilim analizi yapılarak süreç içerisindeki eğilim ortaya konur.

Yukarıda bahsedilen istatistiksel yöntemler, konum-zaman küpleri ile zamana bağlı sıcak nokta analizinin teorisini oluşturan yöntemlerdir. Konum-zaman küplerinin oluşturulma süreci, çalışmada kullanılan nokta veriler üzerinden açıklanmıştır.




Şekil 5. Nokta verilerin x ve y boyutu (Vale, 2018)

Şekil 5’de gösterilen her nokta, bir koordinattan yani x ve y boyutundan oluşmaktadır. Eğer veri seti zaman ve konum bakımından bölünemez ise Şekil 5’deki gibi ifade edilir.



Şekil 6. Nokta verilerin x, y ve t boyutu (Vale, 2018)

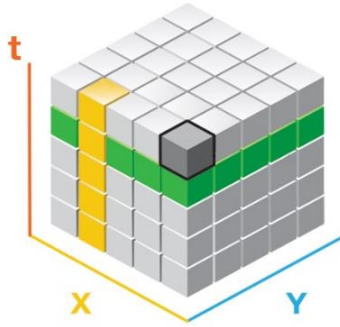
Şekil 6'da konum-zaman küplerinin oluşturulabilmesi için noktaların x ve y noktalarına bir de t boyutu eklenir. Bu t boyutu zamanı temsil eder ve Şekil 6'daki gibi gösterilir.



Şekil 7. Noktaların toplanması sonucu oluşan küpler (Vale, 2018)

Konum-zaman küpleri ile noktalar, belirlenen zaman dilimlerine ve belirlenen mesafeye göre kutular (bins) içerisinde toplanır ve küp halinde Şekil 7'deki gibi gösterilir.

Konum-zaman küplerinin oluşturulabilmesi için en az 60 adet nokta verisine; eğilim analizi için en az 10 zaman dilimine gereksinim vardır.





















Şekil 8. Küplerin oluşturduğu zaman serisi (Vale, 2018)

Şekil 8'de görülen koyu gri renkteki küp, aynı konumdaki ve aynı zaman dilimindeki nokta veriler ile oluşturulur. Bu küpler yatay ekseninde yeşil renkteki gibi Getis-Ord G_i^* istatistiği kullanılarak birleştirilir ve belirli bir zaman dilimi için konumsal veri seti oluşturulur. Bu sayede veri hem klasik sıcak nokta analizi hem de zamana bağlı sıcak nokta analizine uygun hale getirilir. Dikey ekseninde ise küpler sarı renkteki gibi birleştirilerek, belirli bir konum için bir zaman serisi oluşturulur ve Mann-Kendall trend analizine uygun hale getirilir. Yukarıdaki işlemler yapıldıktan sonra veri ArcGIS ortamında çok boyutlu olarak netCDF (Network Common Data Form) formatında saklanır.

Getis-Ord G_i^* istatistiği ve Mann-Kendall trend analizi kullanılarak gerçekleştirilen zamana bağlı sıcak nokta analizindeki sıcak noktalar, zamana bağlı gösterdikleri eğilime göre sınıflandırılabilir. Yapılan sıcak nokta ve eğilim analizlerinden sonra sıcak ve soğuk noktalar için 8 ayrı kategori, toplamda 17 kategori elde edilir. Zamana bağlı sıcak nokta kategorileri Şekil 9 ve Tablo 2 yardımıyla aşağıdaki gibi ifade edilir.

Tablo 2. Zamana bağlı sıcak nokta ifadeleri, isimleri ve tanımları (ESRI, 2022b)

| Şekil | İsmi | Tanımı |
|---|------------------------|---|
|  | Anlamsız | Eğilim analizi sonunda anlamlı bir eğilim tespit edilemeyen nokta |
|  | Yeni sıcak nokta | Daha önceleri anlamsızken son zaman diliminde anlamlı sıcak nokta |
|  | Ardışık sıcak nokta | Daha önceleri anlamsızken tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla son zaman dilimlerinde kesintisiz anlamlı sıcak nokta |
|  | Yoğunlaşan sıcak nokta | Son zaman dilimi de dahil olmak üzere tüm zaman dilimlerinin %90'ını için artan eğilime sahip anlamlı sıcak nokta |
|  | Sürekli sıcak nokta | Tüm zaman dilimlerinin %90'ını içeren ve herhangi bir eğilime sahip olmayan anlamlı sıcak nokta |
|  | Azalan sıcak nokta | Son zaman dilimi de dahil olmak üzere tüm zaman dilimlerinin %90'ını için azalan eğilime sahip anlamlı sıcak nokta |
|  | Aralıklı sıcak nokta | Dönem dönem aralıklarla sıcak nokta olup diğer dönemlerde anlamsız olan ve tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla anlamlı sıcak nokta |
|  | Kararsız sıcak nokta | Son zaman dilimlerinde sıcak nokta olup önceki zaman dilimlerinde soğuk nokta olan ve tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla anlamlı sıcak nokta |
|  | Tarihi sıcak nokta | Son zaman aralığı sıcak nokta olmamakla birlikte tüm zaman dilimlerinin %90'ı anlamlı sıcak nokta |
|  | Yeni soğuk nokta | Daha önceleri anlamsızken son zaman diliminde anlamlı soğuk nokta |
|  | Ardışık soğuk nokta | Daha önceleri anlamsızken tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla son zaman dilimlerinde kesintisiz anlamlı soğuk nokta |
|  | Yoğunlaşan soğuk nokta | Son zaman dilimi de dahil olmak üzere tüm zaman dilimlerinin %90'ını için artan eğilime sahip anlamlı soğuk nokta |
|  | Sürekli soğuk nokta | Tüm zaman dilimlerinin %90'ını içeren ve herhangi bir eğilime sahip olmayan anlamlı soğuk nokta |
|  | Azalan soğuk nokta | Son zaman dilimi de dahil olmak üzere tüm zaman dilimlerinin %90'ını için azalan eğilime sahip anlamlı soğuk nokta |
|  | Aralıklı soğuk nokta | Dönem dönem aralıklarla soğuk nokta olup diğer dönemlerde anlamsız olan ve tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla anlamlı soğuk nokta |
|  | Kararsız soğuk nokta | Son zaman dilimlerinde soğuk nokta olup önceki zaman dilimlerinde sıcak nokta olan ve tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla anlamlı soğuk nokta |
|  | Tarihi soğuk nokta | Son zaman aralığı soğuk nokta olmamakla birlikte tüm zaman dilimlerinin %90'ı anlamlı soğuk nokta |

**Şekil 9.** Küplerin oluşturduğu sıcak-soğuk noktalar (Vale, 2018)

2.3.4. Alanların Belirlenmesi ve Küplerin Oluşturulması


Çalışmada, Karayolları Genel Müdürlüğü'nün web sitesinde yayınlanan durma ve intikal sürelerinden yararlanılarak, uzaklığa bağlı konumsal ilişkiler kurulmuştur. Kent merkezi ve merkez ilçelere bağlı çevre yollarında 90 km/sa maksimum hız için fren mesafesi yaklaşık 53,1 metredir (TCK, 2022). Kaza noktaları arasındaki konumsal ağırlık matrisi oluşturulurken, uzaklığın tersi ile ağırlıklandırma yöntemi kullanılmıştır. Eşik (threshold) değer, maksimum fren mesafesi baz alınarak 50 metre olarak belirlenmiştir. Bu veriler kullanılarak zamanın dikkate alınmadığı klasik sıcak nokta analizi gerçekleştirilmiştir. Zamana bağlı sıcak nokta analizinde nokta veriler için küpler oluşturulurken, isteğe bağlı olarak altıgen şekil kullanılabilir. Çalışma kapsamında yapılan zamana bağlı sıcak nokta analizinde yukarıda bahsedilen kriterler dikkate alınarak 10 yıllık kaza noktalarını içeren küpler oluşturulurken altıgen gösterim tercih edilmiş ve yıllık zaman dilimlerine bölünmüştür.

Sonrasında her bir altıgenin içerisinde kalan kazalar saydırılmış ve kaza toplamları elde edilmiştir. Ardından yatay eksende Getis Ord Gi* istatistiği, son olarak yatay eksendeki sıcak noktaların dikey eksendeki eğilimleri Mann-Kendall trend analizi ile gerçekleştirilip, Tablo 2'ye göre sınıflandırılmıştır.

3. Bulgular

3.1. Klasik Sıcak Nokta Analizi Bulguları

Kent merkezinde tespit edilen sıcak noktalar incelendiğinde, başta Odunpazarı meydanı olmak üzere şehrin genelindeki ana kavşak ve meydanlarda farklı türde sıcak noktalar olduğu tespit edilmiştir. Şekil 10'da trafik kazalarının yoğunlaştığı ve sıcak noktaların tespit edildiği bölgeler gösterilmiştir.



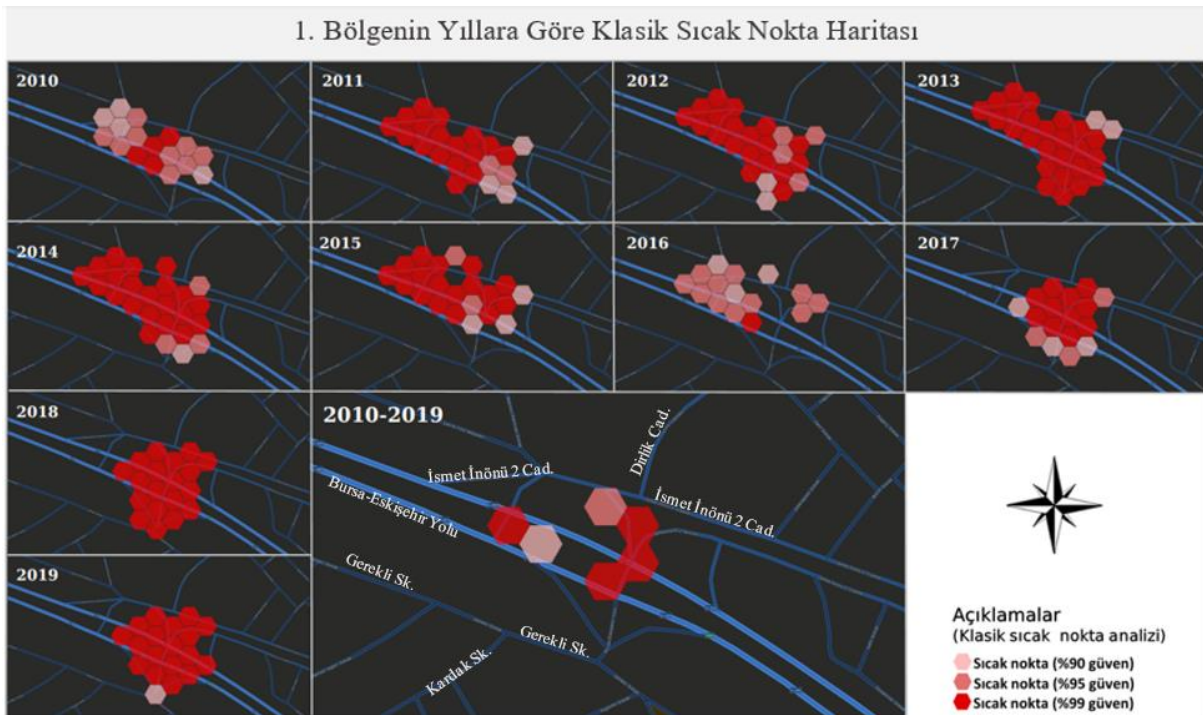
Şekil 10. Eskişehir kent merkezindeki trafik kazalarının klasik sıcak noktaları

Klasik sıcak nokta analizi sonuçlarına göre kent merkezinde genel olarak Atatürk Caddesi, İsmet İnönü 2 Caddesi ve Prof. Dr. Yılmaz Büyükerşen Caddesi üzerinde sıcak noktaların yoğunlaştığı görülmektedir. Şehir içerisinde demir yolu ağının, porsuk çayının ve eski fabrikaların geniş alanlar kaplaması nedeniyle bu güzergaha alternatif yollar geliştirilememiştir. Benzer durum Yunus Emre Caddesi ve Hasan Polatkan Bulvarı için de geçerlidir. Yapılan klasik sıcak nokta analizinde, aşağıda sonuçları verilen zamana bağlı sıcak nokta analizine göre belirlenen kritik bölgeler incelenmiştir. Söz konusu 5 kritik bölgede klasik sıcak nokta analizi ile 15 sıcak nokta tespit edilmiştir. Klasik sıcak nokta analizi, %90, %95 ve %99 güven ve sırasıyla %10, %5 ve %1 anlamlılık seviyelerine göre sonuçlar vermektedir. Çalışma kapsamında değerlendirildiğinde, sıcak nokta olarak tespit edilen her bir altıgenin ve komşularının, bütün veri seti içerisindeki altıgenlerden istatistiksel olarak bir farkı olup olmadığı, güven ve anlamlılık seviyelerine göre belirlenebilmektedir.

İsmet İnönü 2 Caddesi ve Bursa yolunu bağlayan kavşak noktasında, İsmet İnönü 2 Caddesine giriş-çıkış bağlantı noktasında kazalarda %90, %95 ve %99 olmak üzere üç güven düzeyinde anlamlı bir yoğunluk olduğu gözlemlenmiştir. Cumhuriyet-Balsu Bulvarı kesişiminde %99 güven seviyesinde anlamlı bir yoğunluk gözlemlenmiştir.

Sıcak noktaların konumları dikkate alındığında, Cumhuriyet Bulvarından Balsu Bulvarına çıkış istikametinde risk faktörünün yüksek olduğu görülmektedir. Şehit Yüzbaşı Güngör Caddesi-Zümrüt Bulvarı-Mustafa Özel Bulvarı ve Gençlik Bulvarını birleştiren kavşakta kazaların, Zümrüt Bulvarından kavşağa giriş yönünde %90 ve %95 güven düzeyinde yoğunluk gösterdiği tespit edilmiştir. Buna göre Zümrüt Bulvarı'ndan Mustafa Özel Bulvarı ve Gençlik Bulvarına dönüş noktalarında kaza riskinin yüksek olduğu görülmektedir. Eskişehir Osmangazi Üniversitesi bitişiğinde yer alan, Atatürk ve Gençlik Bulvarlarını bağlayan kavşak incelendiğinde, kazaların bağlantı noktasında ve Karadağ Sokağı Atatürk bulvarına bağlayan kısmında gerçekleştiği görülmektedir. %99 güven düzeyinde tespit edilen sıcak noktalara bakıldığında kazaların, Atatürk Bulvarının Gençlik Bulvarı ile kesiştiği devam güzergahı, Gençlik Bulvarına giriş noktaları ve Karadağ Sokağı Atatürk Bulvarına bağlayan hatta yoğunlaştığı gözlemlenmiştir. Kar Sokaktan (Dede Korkut Parkı-Türk Dünyası Doğa Parkı) Atatürk Bulvarına çıkan bağlantı noktasında özellikle sokaktan bulvar çıkışın gerçekleştiği noktalarda önemli bir yoğunluk tespit edilmiştir.

Şekil 11'de İsmet İnönü 2 Caddesi ve Bursa yolunu bağlayan kavşakta (1. bölge) her bir yıl için oluşan sıcak noktalar ve tüm yılların ortalaması alınarak oluşturulan sıcak noktalar verilmiştir.



Şekil 11. Yıllara göre klasik sıcak nokta analizi sonuçları

3.2. Zamana Bağlı Sıcak Nokta Analizi Bulguları

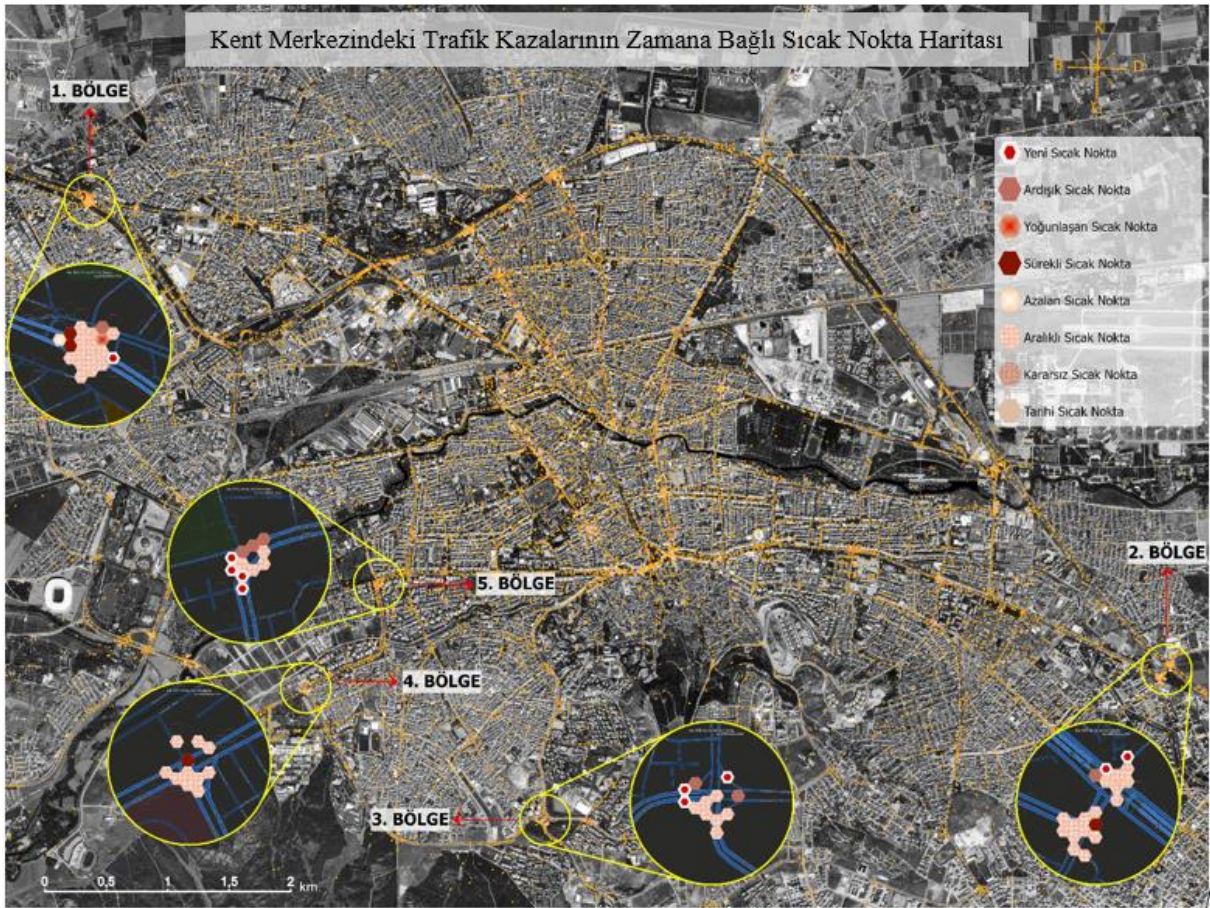
Zamana bağlı sıcak nokta analizinden elde edilen bulgulara göre; Eskişehir kent merkezinde, özellikle merkezi sayılabilecek yollarda birçok sıcak nokta tespit edilmiştir. Kent merkezinin araç sayısı ve insan nüfusu bakımından kalabalık olması, yolların yeterince geniş olmaması gibi faktörlerden dolayı ortaya çıkan sıcak noktaların kabul edilebilir seviyede mantıklı olduğu düşünülmektedir. Diğer yandan, insan ve araç yoğunluğunun nispeten daha az olduğu noktalarda görülen sıcak noktaların, bölgesel anlamda yorumlanması gereken kritik noktalar olduğu görülmüştür. Zamana bağlı sıcak nokta analizi sonucunda kent merkezinde 5 kritik nokta tespit edilmiştir. Bu 5 noktada 50 aralıklı, 10 yeni, 7 ardışık, 4 sürekli, 1 azalan ve 1 yoğunlaşan olmak üzere toplam 73 sıcak nokta tespit edilmiştir.

Zamana bağlı sıcak nokta analizi ile Eskişehir kent merkezinde gerçekleşen trafik kazalarının yoğunlaştığı bölgeler Şekil 12'deki gibidir. Şekil 12'deki 1. bölgede gösterilen kavşak, Bursa istikametinden Eskişehir'e giriş noktasıdır. Ayrıca, şehrin farklı bölgelerine bağlantı yollarının kesiştiği ve Bursa il yolunun başladığı noktadır. Bunların dışında, çevre yoluna çıkan bazı bağlantı yolları ışıklandırma sistemine sahip olmayıp, karmaşık bir yapıya sahiptir. Bursa yolunun Eskişehir'e giriş yönünden, İsmet İnönü 2 Caddesine bağlandığı noktada kazaların son dönemlerde yoğunlaştığı ve çok yüksek riskli bölge olduğu tespit edilmiştir. Ayrıca, kavşağın yaklaşık 50 metre doğusunda kalan ve Eskişehir-Bursa istikametinden İsmet İnönü 2 Caddesine geçiş sağlayan bağlantı yolunda, son 1 senelik dönemde kazaların yoğunlaştığı görülmüş ve riskli bölge olarak tespit edilmiştir. Kavşağın yaklaşık 50 metre batısında kalan bağlantı noktalarında kazaların sürekli yoğun olduğu ve çok yüksek risk taşıdığı gözlemlenmiştir.

Ek olarak, kavşağın kalan bölümleri nispeten daha az riske sahiptir ve düşük riskli olarak tanımlanmıştır. Çevre yoluna bağlanan İsmet İnönü 2 Caddesinin yaklaşık 400 metre gerisinde yer alan Şirintepe parkının bitiminde birleşen dört yol ağzında yeni sıcak noktaların olduğu tespit edilmiştir. Caddenin iki yönünde ve parkın yanından caddeye bağlanan Kolej Sokak çıkışında son 1 senelik periyotta yükselen bir kaza eğilimi gözlenmiştir.

Şekil 12'deki 2. bölge, Cumhuriyet-Balsu Bulvarı kesişimi ve Balsu Bulvarı-Ankara Çevre Yolu-Alpu Yolu bağlantısını sağlayan kavşak görülmektedir. Cumhuriyet ve Balsu Bulvarları kesişiminde genel olarak kaza yoğunluklarının düşük riskli olduğu görülmüştür. Cumhuriyet Bulvarının Çevre Yolu kavşağına dönüşünde Balsu Bulvarı ile kesiştiği noktada sürekli bir kaza yoğunluğu bulunmaktadır ve yüksek riskli olarak tespit edilmiştir. Bu noktada kamera ve radar sistemi bulunmasına rağmen, sistematik bir ışıklandırma sistemi bulunmamaktadır. Düşük de olsa bölgenin kazalar açısından riskli olduğu tespit edilmiştir. Balsu Bulvarı-Çevre ve Alpu Yolu bağlantısını sağlayan kavşakta kuzeybatıdan güneydoğuya Eskişehir çıkış istikametine ilerleyen Çevre Yolunun kavşak önü yön değiştirme bağlantı noktasında kazaların riskli sınıfında yer aldığı görülmektedir. Bu bağlantı noktasının girişinde genel olarak kazaların yoğun olduğu, çıkış noktasında ise son 1 senelik periyotta kazaların yoğunlaştığı görülmektedir.

Ayrıca kavşağa bağlanan Alpu Yolu mevkiinde, yolun çift yön olarak başladığı nokta ve caddeye kuzeyden bağlanan Çilekçi Sokak kesişiminde son 1 senelik periyotta kazaların yoğunlaştığı görülmüştür ve bu bölge riskli olarak tespit edilmiştir. Son olarak, kavşağın genel hat itibarıyla kazalar açısından riskli bulunmaktadır ve kalan bölgeler düşük risk sınıfında yer almaktadır.



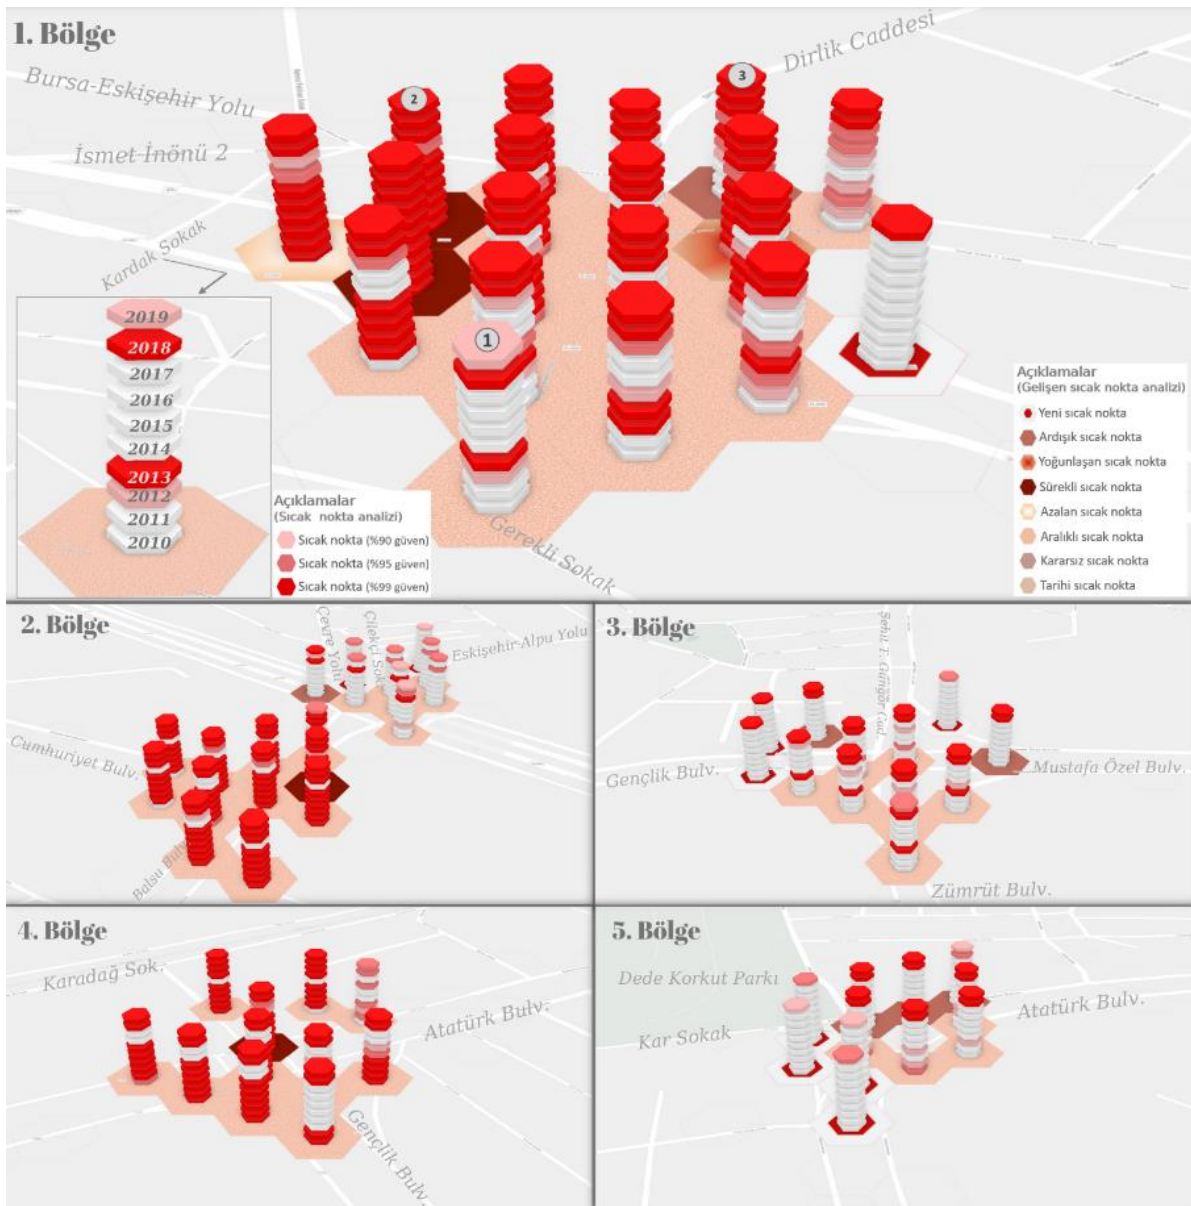
Şekil 12. Eskişehir kent merkezindeki trafik kazalarının zamana bağlı sıcak noktaları

Şekil 12'deki 3. bölge, Şehit Yüzbaşı Güngör Caddesi-Zümrüt Bulvarı-Mustafa Özel Bulvarı ve Gençlik Bulvarını birleştiren kavşak yer almaktadır. Zümrüt Bulvarından Mustafa Özel Bulvarına çıkış bağlantı yolu ve Mustafa Özel Bulvarını Şehit Yüzbaşı Güngör Bulvarına bağlayan yolun giriş kısmında kazalar yoğun ve riskli bölge sınıfında yer almaktadır. Yine Mustafa Özel Bulvarını Şehit Yüzbaşı Güngör Bulvarına bağlayan yolun ilerleyen kısmında son 1 senelik periyotta oluşan bir kaza yoğunluğu gözlenmiştir ve riskli bölge sınıfında yer almaktadır. Aynı şekilde Şehit Güngör Caddesini Gençlik Bulvarına bağlayan yol çıkışı ve Gençlik Bulvarını Zümrüt Bulvarına bağlayan yol girişinde kazalar yoğunlaşmıştır ve riskli bölge olarak tespit edilmişlerdir. Yolların birleştiği göbek, Zümrüt Bulvarına bağlanan yollar ve bağlantılardan sonraki 50 metrelik yolu kapsayan alan düşük riskli bölgeler olarak tespit edilmiştir.

Şekil 12'deki 4. bölge, Eskişehir Osmangazi Üniversitesi bitişiğinde yer alan, Atatürk ve Gençlik Bulvarlarını bağlayan kavşaktır. Özellikle Atatürk Bulvarı ve Karadağ Sokağın birleştiği yol ağı kısmında sürekli bir kaza yoğunluğu görülmüş ve çok yüksek riskli olarak tespit edilmiştir. Atatürk Bulvarının doğu yönünden kavşağa yaklaşılacak bölge, Gençlik Bulvarından Atatürk Bulvarı doğu yönü istikameti bağlantı yolunu kapsayan bölge ve batıdan Atatürk Bulvarı-Gençlik Bulvarı bağlantısının sağlandığı alanlarda kazaların yoğunlaştığı görülmüş ve düşük riskli olarak tespit edilmiştir. Son olarak, Atatürk Bulvarı üzerinde bulunan ve kavşağın 250 metre doğusunda kalan yol üzerinde son 1 senelik periyotta kazaların yoğunlaştığı görülmüş ve riskli bölge olarak tespit edilmiştir.

Şekil 12'deki 5. bölge, Kar Sokaktan (Dede Korkut Parkı-Türk Dünyası Doğa Parkı) Atatürk Bulvarına çıkan bağlantı noktası bulunmaktadır. Bulvardan sokağa giriş ve sokaktan bulvara çıkış noktalarında kazaların yoğun olduğu gözlenmiştir. Giriş bağlantı yolunda kazalar genel olarak yoğundur ve riskli bölge olarak tespit edilmiştir. Aynı şekilde çıkış yolu üzerinde özellikle son 1 senelik periyotta kazaların yoğunlaştığı gözlenmiştir. Ayrıca sokağın bulvara Odunpazarı yönü çıkışında kazaların yine yoğunlaştığı fakat diğer bağlantı noktaları kadar önemli olmadığı tespit edilmiştir. Bu nedenle bu çıkış yolu düşük risk sınıfında yer almaktadır.

Çalışma amacının görsel olarak daha net anlaşılabilmesi için Eskişehir kent merkezindeki trafik kazalarının yoğunlaştığı beş bölge için klasik sıcak nokta analizi sonuçlarının 3 boyutlu ve zamana bağlı sıcak nokta analizi sonuçlarının 2 boyutlu gösterimi Şekil 13'deki gibidir.



Şekil 13. Eskişehir kent merkezindeki trafik kazalarının yoğunlaştığı beş kritik bölgenin 3 boyutlu (klasik sıcak nokta) ve 2 boyutlu (zamana bağlı sıcak nokta) gösterimi

Çalışmanın bulguları incelendiğinde, zamana bağlı sıcak nokta analizinin klasik sıcak nokta analizine göre daha detaylı sonuçlar verdiği görülmüştür. Bu detaylı sonuçların ana nedeni, zamana bağlı sıcak nokta analizinin zaman faktörünü dikkate alarak belirlenen konumlardaki eğilimleri hesaplamalara dahil etmesidir. Şekil 13'deki 1. bölgedeki 1 numaralı konuma bakıldığında, klasik sıcak nokta analizine göre %90, %95 ve %99 güven düzeylerine göre 2010 ve 2011 yılları anlamsız yani sıcak nokta olarak tespit edilememiştir. 2012 yılı %90 ve 2013 yılı %99 güven düzeyine göre sıcak nokta olarak belirlenmiştir. 2012 ve 2013 yıllarında 1. konum sıcak nokta iken, 2013 yılında bu nokta daha riskli hale gelmiştir. Takip eden 4 yılda (2014, 2015, 2016 ve 2017 yılları) bu konum risksiz olarak görülmektedir. 2018 yılında %99 ve 2019 yılında %90 güven düzeyinde bu konum tekrar sıcak nokta haline gelmiştir. Yalnızca klasik sıcak nokta analizi sonuçlarına göre kaza yoğunluğunu belirlemek yanıltıcı sonuçlara neden olabilmektedir. Zamana bağlı sıcak nokta analizi ile 1. bölge 1. konumun aralıklı sıcak nokta olduğu tespit edilmiştir.

Yani bu konumun; dönem dönem aralıklarla sıcak nokta, diğer dönemlerde anlamsız ve tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla anlamlı sıcak nokta olduğunu göstermektedir. Klasik sıcak nokta analizine göre 1. bölge 2. konum, 2016 yılında %95, geri kalan tüm yıllarda %99 güven düzeyinde sıcak nokta olarak tespit edilmiştir. Zamana bağlı sıcak nokta analizinde zamanın da analize dahil edilmesi bu konumun sürekli sıcak nokta olarak tanımlanmasını sağlamaktadır. Bunun anlamı 2. konumun tüm zaman dilimlerinin %90'ını içermesi ve herhangi bir eğilime sahip olmayan anlamlı sıcak noktalardan oluşmasıdır.

1. bölge 3. konumun klasik sıcak nokta analizi sonuçları 2010, 2011 ve 2012 yıllarının anlamsız olduğunu göstermektedir. 2013 yılında %90, 2014'te %95, 2015'te %99, 2016'da %95 ve kalan son 3 yılda %99 güven düzeyinde sıcak noktalar tespit edilmiştir. Zamana bağlı sıcak nokta analizinde bu sonuçların karşılığı, 3. konumun ardışık sıcak nokta olduğudur. Yani bu noktada, daha önceki zaman dilimleri anlamsız, fakat tüm zaman dilimlerinin %90'ından daha az olmak kaydıyla son zaman dilimlerinde kesintisiz anlamlı sıcak noktalar görüldüğüdür. Yukarıdaki açıklamaların benzerleri 5 kritik bölgedeki her konum için Tablo 2 baz alınarak yapılabilmektedir.

4. Sonuç ve Tartışmalar

Analiz sonuçları incelendiğinde zamana bağlı sıcak nokta analizinin, klasik sıcak nokta analizine göre kent merkezinin farklı konumlarında ve farklı desenlerde sıcak noktaların tespit edilmesini sağladığı görülmüştür. Klasik sıcak nokta analizinde çalışma alanı içerisinde belirlenen 5 kritik bölgede yalnızca 15 sıcak nokta tespit edilmişken; zamana bağlı sıcak nokta analizi ile bu noktaların 73'e çıktığı görülmüştür. Klasik sıcak nokta analizi sonuçları ile zamana bağlı bir yorum yapmak ya da kaza desenlerini tespit etmek mümkün değildir. Yalnızca belirlenen noktanın istatistiksel olarak anlamlı bir sıcak nokta olup olmadığı belirlenebilmektedir. Zamana bağlı sıcak nokta analizindeki anlamlı noktalar daha geniş bir alana yayılmıştır. Seçilen bölgelerde belirlenen 50 aralıklı sıcak nokta, belirli dönemlerde kazaların anlamlı bir şekilde yoğunlaştığını ifade etmektedir. Ayrıca zamana bağlı sıcak nokta analizine göre tespit edilen 10 yeni sıcak nokta, son dönemlerde yaşanan kaza yoğunluklarını ifade etmektedir. Zaman faktörünün dikkate alınmaması özellikle bu iki sınıfa ait kaza noktaları daha dar bir alanda anlamlı çıkacağından ve bazı yerlerde anlamsız çıkacağından tanımlamalarda, yorumlamalarda ve gerekli önlemlerin alınmasında bilgi kaybına neden olacaktır. Bu da zaman faktörünün yani eğilimin kaza noktalarının üzerindeki etkisini göstermektedir.

Klasik sıcak nokta ve zamana bağlı sıcak nokta analiz sonuçları birlikte incelendiğinde; 1. bölge için klasik sıcak nokta analizi ile 6, zamana bağlı sıcak nokta analizi 19; 2. bölge için klasik sıcak nokta analizi ile 2, zamana bağlı sıcak nokta analizi 20; 3. bölge için klasik sıcak nokta analizi ile 3, zamana bağlı sıcak nokta analizi 12; 4. bölge için klasik sıcak nokta analizi ile 3, zamana bağlı sıcak nokta analizi 11 ve 5. bölge için klasik sıcak nokta analizi ile 1, zamana bağlı sıcak nokta analizi 11 sıcak nokta tespit edilmiştir. Bu farklılıkların nedeni, klasik sıcak nokta analizinde veri setinin zamana göre bölünmemiş olması, zamana bağlı sıcak nokta analizinde veri setinin zamana göre bölünerek her bir zaman dilimi için ayrı ayrı analizler gerçekleştirilmesidir. Zamana bağlı sıcak nokta analizinde bazı yıllarda belirlenen bölgelerde kaza sayılarında yoğunlaşma yaşanmış ve yıllar içerisindeki eğilim de anlamlı çıktığı için bu bölgeler sıcak noktalar olarak tanımlanmıştır. Bu bölgelerdeki yıllara bağlı altıgenler incelendiğinde bazılarında dönemsel olarak sıcak noktaların olduğu ama hepsinde son yılların sıcak nokta olarak çıktığı görülmektedir. Başka bir ifadeyle bu bölgelerde bazı yıllarda kazalarda yoğunlaşma yaşanmamıştır ve klasik yöntemle analiz yapıldığında genel olarak buraların anlamsız çıkmasına neden olmuştur. Ancak son yıllarda yaşanan kaza yoğunlukları altıgenlerin aslında sıcak nokta olma potansiyelini göstermekte ve bu durum zamana bağlı sıcak nokta analizi ile desteklenmektedir.

Bu çalışma ile trafik kazalarının yoğunlaştığı bölgelerin daha ayrıntılı şekilde tespit edilebilmesi, nitelikli yorumlar ve çözümler üretilebilmesi açısından zamana bağlı sıcak nokta analizinin daha iyi bir açıklayıcı olduğu belirlemiştir. Tüm sonuçlar birlikte incelendiğinde, verilerin zamana bağlı analizleri ile daha detaylı sonuçlar elde edilebildiği görülmüştür. Özellikle trafik kazaları, sağlık, ekonomi gibi zamansal eğilimin ve değişimin dikkate alınması gereken alanlarda zamana bağlı sıcak nokta analizinin kullanılmasının daha detaylı ve gerçekçi sonuçlar elde etmeye olanak sağlayacağı düşünülmektedir. Çalışma sonucunda klasik sıcak nokta analizinin anlamsız çıkardığı altıgenlerin, zamana bağlı sıcak

nokta analizi ile anlamlı noktalar olduğu tespit edilmiş ve trafik kazaları gibi hayati bir olay dikkate alındığında çalışmada uygulanan yöntemin farkı ve gerekliliği ortaya konmuştur.

Kaynaklar

- Afolayan, A., Easa, S. M., Abiola, O. S., Alayaki, F. M., & Folorunso, O. (2022). GIS-based spatial analysis of accident hotspots: A Nigerian case study. *Infrastructures*, 7(8), 103. doi: 10.3390/infrastructures7080103.
- Amiri, A. M., Nadimi, N., Khalifeh, V., & Shams, M. (2021). GIS-based crash hotspot identification: a comparison among mapping clusters and spatial analysis techniques. *International Journal of Injury Control and Safety Promotion*, 28(3), 325-338.
- Anderson, T. K. (2009). Kernel density estimation and K-means clustering to profile road accident hotspots. *Accident Analysis & Prevention*, 41(3), 359-364.
- Bil, M., Andrasik, R., & Sedonik, J. (2019). A detailed spatiotemporal analysis of traffic crash hotspots. *Applied Geography*, 107, 82-90.
- Cheng, Z., Zu, Z., & Lu, J. (2018). Traffic crash evolution characteristic analysis and spatiotemporal hotspot identification of urban road intersections. *Sustainability*, 11(1), 160. doi: 10.3390/su11010160.
- De Silva, V., Tharindra, H., Vissoci, J. R. N., Andrade, L., Mallawaarachchi, B. C., Ostbye, T., & Staton, C. A. (2018). Road traffic crashes and built environment analysis of crash hotspots based on local police data in Galle, Sri Lanka. *International Journal of Injury Control and Safety Promotion*, 25(3), 311-318.
- ESRI. (2022a, June 8). *ArcGIS Pro Resources, How create space sime cube works*. Retrieved from <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/space-time-pattern-mining/learnmorecreatecube.htm>
- ESRI. (2022b, June 8) *ArcGIS Pro Resources, How emerging hot spot analysis works*. Retrieved from <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/space-time-pattern-mining/learnmoreemerging.htm>
- Getis, A., & Ord, J. K. (1992). The analysis of spatial association by use of distance statistics. *Geographical Analysis*, 24(3), 189-206.
- Gudes, O., Varhol, R., Sun, Q., & Meuleners, L. B. (2017). Investigating articulated heavy-vehicle crashes in Western Australia using a spatial approach. *Accident Analysis and Prevention*, 106, 243-253.
- Hayidso, T. H., Gameda, D. O., & Abraham, A. M. (2019). Identifying road traffic accidents hotspots areas using GIS in Ethiopia: A case study of Hosanna Town. *Transport and Telecommunication*, 20(2), 123-132.
- Hazaymeh, K., Almagbile, A., & Alomari, A. H. (2022). Spatiotemporal analysis of traffic accidents hotspots based on geospatial techniques. *ISPRS International Journal of Geo-Information*, 11(4), 260. doi: 10.3390/ijgi11040260.
- Kang, Y., Cho, N., & Son, S. (2018). Spatiotemporal characteristics of elderly population's traffic accidents in Seoul using space-time cube and space-time Kernel density estimation. *PLoS ONE*, 13(5), e0196845. doi: 10.1371/journal.pone.0196845.
- Kang, Y., Son, S., & Nahye, C. (2017). Analysis of traffic accidents injury severity in Seoul using decision trees and spatiotemporal data visualization. *Journal of Cadastre & Land InformatiX*, 47(2), 233-254.
- Li, Y., Zhang, L., Yan, J., Wang, P., Hu, N., Cheng, W., & Fu, B. (2017). Mapping the hotspots and coldspots of ecosystem services in conservation priority setting. *Journal of Geographical Sciences*, 27(6), 681-696.
- Moons, E., Brijs, T., & Wets, G. (2009). Improving Moran's Index to identify hot spots in traffic safety. In B. Murgante, G. Borruo, & A. Lapucci (Eds.), *Geocomputation and Urban Planning: Studies in Computational Intelligence* (pp. 117-132), Heidelberg: Springer.
- Ord, J. K., & Getis, A. (1995). Local spatial autocorrelation statistics: distributional issues and an application. *Geographical Analysis*, 27(4), 286-306.
- Özmal, M., Küçükönder, M., Karabulut, M., ve Göksu, G. (2014, Haziran). Coğrafi bilgi sistemleri kullanarak Kahramanmaraş trafik kaza analizi. *Coğrafyacılar Derneği Uluslararası Kongresi*. (pp. 867-875).
- Tamakloe, R. & Park, D. (2022). Factors influencing fatal vehicleinvolved crash consequence metrics at spatio-temporal hotspots in South Korea: application of GIS and machine learning techniques. *International Journal of Urban Sciences*, doi: 10.1080/12265934.2022.2134182.
- Thomas, I. (1995). Spatial data aggregation: Exploratory analysis of road accidents. *Accident Analysis and Prevention*, 28(2), 251-264.
- Tobler, W. R. (1970). A Computer movie simulating urban growth in the Detroit region. *Economic Geography*, 46(sub1), 234-240.
- Tola, A. M., Demissie, T. A., Saathoff, F., & Gebissa, A. (2021). Severity, Spatial pattern and statistical analysis of road traffic crash hot spots in Ethiopia. *Applied Sciences*, 11(19), 8828. doi: 10.3390/app11198828.
- TÜİK. (2022, Haziran 8). *Adrese dayalı nüfus kayıt istatistikleri*. Retrieved from <https://data.tuik.gov.tr/Kategori/GetKategori?p=Nufus-ve-Demografi-109>

- Uğur Özçelik, M., Gökçen, H. ve Dağdeviren, M. (2013). Ankara şehir içi otobüs kazalarının analizi ve bölge risklerinin belirlenmesi için birçok ölçütlü karar modeli. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 30, 33-55.
- TCK. (2021). *Trafik kazaları özeti*. Ulaştırma ve Altyapı Bakanlığı Karayolları Genel Müdürlüğü. Retrieved from <https://www.kgm.gov.tr/Sayfalar/KGM/SiteTr/Trafik/TrafikKazalariOzeti.aspx>
- TCK. (2022). *Durma ve intikal süreleri*. Ulaştırma ve Altyapı Bakanlığı Karayolları Genel Müdürlüğü. Retrieved from <https://www.kgm.gov.tr/Sayfalar/KGM/SiteTr/Trafik/DurmaIntikal.aspx>
- Vale, F. (2018, March). Spatial data mining II: A deep dive into space-time analysis. ESRI Federal GIS Conference. Washington DC: USA.
- WHO. (2022, June 20). *Road traffic injuries*. World Health Organization. Retrieved from <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- Wu, P., Meng, X., & Song, L. (2021). Identification and spatiotemporal evolution analysis of high-risk crash spots in urban roads at the microzonelevel: Using the space-time cube method. *Journal of Transportation Safety&Security*. doi: 10.1080/19439962.2021.1938323
- Xie, Z., & Yan, J. (2008). Kernel density estimation of traffic accidents in a network space. *Computers, Environment and Urban Systems*, 32(5), 396-406, 2008.
- Yıldırım, V., & Mert Kantar, Y. (2020). Spatial analysis of the road traffic accidents statistics in the provinces of Turkey. *SIGMA Journal of Engineering and Natural Sciences*, 38(4), 1667-1680.
- Yohannes, A. Y. W., and Minale, A. S. (2015). Identifying the hot spot areas of road traffic accidents. *Jordan Journal of Civil Engineering*, 9(3), 358-370.
- Yoon, J., & Lee, S. (2022). Spatio-temporal patterns in pedestrian crashes and their determining factors: Application of a space-time cube analysis model. *Accident Analysis & Prevention*, 161, 106291. doi: 10.1016/j.aap.2021.106291.

Türkiye'deki 2000 – 2021 Yılları Arasındaki Bitki Örtüsü Yangınlarının Mekânsal Analizi

Spatial Analysis of Wildfires in Türkiye between 2000 – 2021

Özer Akyürek^{1*} 

¹Kocaeli Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 41001, Kocaeli/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Özer Akyürek
oz.er.akyurek@kocaeli.edu.tr

doi: 10.48123/rsgis.1179051

Yayın süreci

Geliş tarihi: 22.09.2022
Kabul tarihi: 22.11.2022
Basım tarihi: 28.03.2023

Özet

Doğal veya insani sebeplerden meydana gelen yangınlar, yeryüzünde yaşayan tüm canlıları etkileyen en önemli doğal afetlerden bir tanesidir. Yeryüzünde her yıl ortalama olarak 3-5 milyon km²lik ormanlık alan yanmaktadır. Meydana gelen yangınlar, canlıları etkileyen küresel ısınma, atmosferde bulunan hava kirlenici parametrelerin yoğunluğunda artış vb. çeşitli faktörler meydana getirmektedirler. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri gelişen günümüz teknolojisinde meydana gelen doğal afetlerin izlenmesinde ve yönetiminde sıklıkla başvurulan araçlardır. Konumsal verileri yönetmedeki başarısı, konumsal analiz yapabilme yeteneği, sonuçları sunabilme ve görselleştirme kapasitesi nedeniyle sıklıkla tercih edilmektedir. Bu çalışmada 2000 – 2021 yılları arasında Türkiye'de ormanlık ve otlak alanlarda meydana gelen bitki örtüsü yangınları mekânsal istatistik yöntemlerle incelenerek analizi yapılmış ve haritalandırılması sağlanmıştır. Analizler sonucunda 21 yıllık süreç içerisinde ormanlık alan yangınlarından en çok etkilenen bölgelerin Ege, Akdeniz ve Güneydoğu Anadolu bölgeleri, otlak alan yangınlarından ise İç ve Güneydoğu Anadolu bölgesi olduğu tespit edilmiştir. Ormanlık alan yangınlarından en çok etkilenen ilin Antalya, otlak alan yangınlarından en çok etkilenen ilin ise Şanlıurfa olduğu belirlenmiştir.

Anahtar kelimeler: Bitki örtüsü yangını, Mekânsal istatistik, FIRMS, Moran's I, Getis Ord Gi*, Anselin yerel moran's I

Abstract

Fires caused by natural or human causes are one of the most important natural disasters that affect all living things on earth. Fires cause an average of 3-5 million km² of area to burn annually. Fires that occur, global warming affecting living things, increase in the density of air pollutant parameters in the atmosphere, etc. is caused by various factors. Remote Sensing and Geographic Information Systems are frequently used in the monitoring and management of natural disasters that occur in today's developing technology. It is preferred because of its success in managing spatial data, ability to perform spatial analysis, and capacity to present and visualize results. In this study, vegetation fires that occurred in forest and grassland areas in Türkiye between 2000 and 2021 were analyzed and mapped by using spatial statistical methods. As a result of the analysis, it has been determined that the regions most affected by forest fires in the 21-year period are the Aegean, Mediterranean and Southeastern Anatolia regions and Central and Southeastern Anatolia regions by grassland fires. It has been determined that the province most affected by forest fires is Antalya, and the province most affected by grassland fires is Şanlıurfa.

Keywords: Wildfires, Spatial statistics, FIRMS, Moran's I, Getis Ord Gi*, Anselin local moran's I

1. Giriş

Yangınlar, doğal veya insan kaynaklı sebeplerden ortaya çıkan, meydana geldiği bölgede bulunan canlı, cansız varlıklara kısmen veya tamamen zarar veren bir olgu olarak tanımlanmaktadır (Busico vd., 2019; Çetin vd., 2022; Sarı, 2021). Karasal bitki örtüsünü şekillendiren, yeryüzünde bulunan biyomların dağılımını etkileyen ve canlıların evrimine yön veren bir ekosistem süreci olarak da adlandırılabilir (Tavşanoğlu, 2017). Yerküre üzerindeki başlıca bitki örtüsü tipleri; Yarı kurak, Otlak, Savan, Çalılık ve Fundalık, Tundra, Konifer ve Tropikal Yağmur ormanlarıdır. Yağmur ormanlarında yangın miktarı çok fazla kuru materyalin birikmemesinden kaynaklı olarak çok düşük değerlerdedir. Bazı savan ve otlaklarda da yangın miktarları yüksek düzeydeki otçul hayvanın bu bölgelerde yaşamasından kaynaklı olarak düşüktür. Otçul hayvanlar yanıcı madde miktarını azaltmakta ve yangınların oluşmasının önüne geçmektedir. Bunların aksine Akdeniz tipi formasyonlar yüksek yağış miktarına rağmen çok çabuk yanmaktadır. Bu durumun nedeni olarak son derece düşük ayrışım oranına ve düşük otçul hayvan düzeyine sahip olunması gösterilebilir (Arslantürk, 2007; Tavşanoğlu, 2021). Orman alanları dünya kara yüzölçümünün yaklaşık %30'unu oluşturur ve arazi örtüsünde büyük bir paya sahiptir (Sivrikaya ve Küçük, 2022). Orman alanlarının, yeryüzünün doğal yapısını koruması üzerinde atmosferik kirliliği azaltmadan, toprak kaymasına kadar faydalı birçok etkisinin olduğu bilinmektedir. Ayrıca pek çok doğal zenginliğe ev sahipliği yaparak, ülkelerin ekonomilerine çeşitli katkıları da bulunmaktadır (Arca vd., 2020; Karabacak vd., 2019; Sarı, 2022; Zúñiga-Vásquez vd., 2017). Orman yangınları, paleozoik zamandan itibaren geçen süre içerisinde yeryüzünde var olan karasal ekosistemlerin önemli bir parçası olmuştur (Tüfekçioğlu vd., 2022). Doğal (volkanik faaliyetler, yıldırım ve meteorlar vb.) veya insan kaynaklı nedenler (avcılık, piknik, sigara izmariti, terör saldırıları, sabotaj vb.) orman yangınlarına sebep olmaktadır (Busico vd., 2019; Çolak ve Sunar, 2020a; İban ve Şekertekin, 2022; Novo vd., 2020; Sarı, 2022). Dünyada insan kaynaklı nedenlerle çıkan yangınlar, doğal nedenlerle çıkan yangınlardan çok daha fazladır (Chen ve Yang, 2018; Duran, 2014). Türkiye'de 1937-2018 yılları arasında 1,680,000 ha alanın yangınlara maruz kaldığı tespit edilmiştir. Son 20 yılda Türkiye'de %90'ı insan kaynaklı 63,724 orman yangını çıkmıştır (Çetin vd., 2022; Çolak ve Sunar, 2020a). 2020 yılında 3399 adet orman yangını tespit edilmiş ve bu yangınlar sonucunda 20,971 ha alan yanmıştır. 2021 yılı, orman yangınları açısından Türkiye için en kötü yıl olmuş ve yaklaşık 203,000 ha ormanlık alan tahrip olmuştur. 1937 yılından günümüze kadar geçen sürede Türkiye sınırları içerisinde yaklaşık 2,000,000 ha'lık orman alanı yangına maruz kalmıştır (İban ve Şekertekin, 2022; Tariq vd., 2022; Tüfekçioğlu vd., 2022). Son yıllarda meydana gelen orman yangınlarının en büyük sebebi iklim değişikliği olarak gösterilmektedir. İklim değişikliğinin orman yangını rejimleri üzerindeki etkileri de yıldan yıla daha belirgin hale gelmektedir. Avrupa Orman Yangını Bilgi Sistemi (EFFIS) raporuna göre; yangın tehlikesi seviyelerinin arttığı, daha uzun yangın mevsimlerinin varlığı, daha sık ve hızlı yayılan mega yangınların sayıları artış göstermektedir (Çolak ve Sunar, 2020b; Gökkaya, 2022; Trucchia vd., 2022). Son yüzyıl içerisinde pek çok nedene (yangınların baskılanması, ağaçlandırma ve sosyal politikalar vb.) bağlı olarak Akdeniz havzasındaki yangın rejimi değişikliğe uğramıştır. Bunun sonucu olarak da iklim değişikliğinden kaynaklı daha şiddetli ve uzun süren sıcak hava dalgaları, bölgede çıkan yangınların olması gerekenden daha büyük ve uzun sürmesine zemin hazırlamaktadır (Tüfekçioğlu vd., 2022).

Yangınlarla mücadele, yangın öncesi ve sonrası yapılan çeşitli işlem adımlarından oluşmaktadır. Meydana gelen yangınlar öncesinde yapılacak olan işlemler; tespitin gerçekleştirilmesi, erken müdahale adımlarının atılması, oluşturulacak olan risk haritaları ile planlamaların yapılmasını kapsamaktadır. Yangın sonrası yapılacak işlemler ise; meydana gelen zararın araştırılması ve yanan alanların yeniden eski haline geri dönmesi yönünde atılacak olan adımların belirlenmesi olarak sıralanabilir (Gayır ve Arslan, 2018; Novo vd., 2020; Tavşanoğlu, 2021). Yangınların konumsal oluşum örüntüsünü istatistiksel yöntemler ile tanımlamak alınabilecek tedbirler açısından son derece önemlidir (Duran, 2014; Sarı, 2021). Coğrafi Bilgi Sistemleri (CBS) ve Uzaktan Algılama (UA) afet izleme ve yönetiminin tamamlayıcı birer parçasıdır (Çolak ve Sunar, 2020b; Sivrikaya ve Küçük, 2022). CBS; mekânsal gözlemlerle elde edilen vektör ve sözel bilgilerin; depolanması, analizi ve sonuç ürünlerin kullanıcılara veya karar vericilere sunulması adımlarını bir bütünlük içerisinde gerçekleştirmektedir. CBS içerisindeki mekânsal istatistik analizleri; veri gösterimi, haritalandırılması, grafiklendirilmesi ve çeşitli farklı verilerin birbirleriyle ilişkilendirilerek bir arada gösterilmesi gibi kolaylıkları kullanan ve tüm bunların sonucunda veriler arasındaki ilişkiyi ifade eden analizleri tanımlamaktadır (Chen ve Yang, 2018; Gayır ve Arslan, 2018). UA ise yüksek spektral ve konumsal çözünürlükle topladığı veriler ile afetlerin takibi ve yönetiminde sıklıkla kullanılan bir araç olarak öne çıkmaktadır (Gökkaya, 2022; İban ve Şahin, 2022). Ayrıca zamansal çözünürlük yeteneği ile de afet öncesi ve sonrasındaki etkilerin izlenmesi için kullanışlı bir veri kaynağıdır. Mekânsal istatistik, verilerin konum bilgilerini kullanarak onlara istatistiksel test uygulamayı ve mekânsal desen arayışını temsil etmektedir. Mekânsal istatistiğin öncelikli adımlarından bir tanesi mekânsal dağılımın ölçülmesidir. Veri noktalarının örüntüsünü araştırırken, kümelenme, dağınık veya rastlantısal olduklarına karar verilir (Bae vd., 2015).

Yeryüzü üzerinde meydana gelen yangınların mekânsal istatistik analizlerinin yapıldığı literatürde birçok çalışma bulunmaktadır. Gajovic ve Todorovic (2013), Sırbistan'da 2000 - 2013 yılları arasındaki MODIS yangın verilerini kullanarak mekânsal ve zamansal analizler gerçekleştirmişlerdir. Kullandıkları analizler arasında Getis Ord Gi*, Global Moran's I, Anselin Yerel Moran's I bulunmaktadır.

Ayrıca yangın verileri ile arazi örtüsü, eğim, bakı, yükseklik ve solar radyasyon arasındaki ilişkileri de incelemişlerdir. Oom ve Pereira (2013), tüm dünya çapında meydana gelen yangınların mekânsal dağılımlarını incelemişlerdir. MODIS uydu platformu tarafından tespit edilen orman yangınları verilerini kullanarak tüm dünya çapında meydana gelen yangınların Anselin Yerel Moran's I tekniği ile analizlerini gerçekleştirerek mekânsal dağılımlarını belirlemişlerdir. Bae vd. (2015), çalışmalarında Kore'nin Gyeonsangnam-do şehrinde 2007 - 2014 yılları arasında meydana gelmiş olan yangın verilerini incelemişlerdir. Yangınlar sonucunda meydana gelen can ve mal kaybı hasarını mekânsal olarak analiz etmiş ve Global Moran's I ve Getis Ord Gi* tekniklerini kullanarak kümelenme dağılımlarını belirlemişlerdir. Zúñiga-Vásquez vd. (2017), çalışmalarında Meksika'da 2005 - 2015 yılları arasında meydana gelen yangınların mekânsal kümelenmelerini incelemişlerdir. Çalışmalarında Ulusal Orman Komisyonu (National Forest Commission, CONAFOR) ve MODIS verilerini kullanmışlardır. Her iki veri kümesi için uyguladıkları kümeleme analiz sonuçlarını karşılaştırmışlardır. Chen ve Yang (2018), Tayvan'ın güneyinde bulunan Tainan şehrindeki yangınların mekânsal analizini gerçekleştirmişlerdir. Yangınların kümelenmiş bir modele sahip olup olmadıklarını belirlemek için Moran's I ve ortalama en yakın komşu analizini kullanmışlardır. Ayrıca yangınların sıcak ve soğuk noktalarının nerelerde olduğunu haritalayabilmek için Getis Ord Gi* analizinden faydalanmışlardır. Çolak ve Sunar (2020a, 2020b), İzmir'in Menderes bölgesinde meydana gelen yangınlara ait yangın risk haritalarını uydu görüntülerinden faydalanarak oluşturmuşlardır. Oluşturdukları risk haritalarını MODIS ve VIIRS uydularından elde edilen yangın verileri ile karşılaştırarak çalışmalarının validasyon işlemini gerçekleştirmişlerdir. Zahran vd. (2020), Brunei Darussalam'da 2007 - 2016 yılları arasındaki yangınların mekânsal analizini gerçekleştirmişlerdir. Yangınların analizleri için Kernel Density Estimation, Anselin Yerel Moran's I ve Getis Ord Gi* tekniklerini kullanmışlardır. Coşkuner (2022) çalışmasında MODIS ve VIIRS uyduları yardımıyla Türkiye'de tespit edilen yangınların doğruluk performansını incelemiştir. Uydular tarafından tespit edilen yangınları, boyutları ve arazi örtüsü/kullanımı verileri ile karşılaştırarak doğruluk çıkarımında bulunmuştur. İban ve Şekertekin (2022), makine öğrenmesi yöntemleri yardımıyla hazırladıkları Adana ve Mersin illerine ait yangın duyarlılık haritalarının oluşturulması çalışmalarında MODIS yangın verilerinden faydalanmışlardır.

Bu çalışma ile Türkiye'deki 21 yıllık bitki örtüsü yangınlarının mekânsal analizi ve geçen süreç içerisinde meydana gelen yangınların mekânsal örüntüleri belirlenmeye çalışılmıştır. Bu zamana kadar yapılmış benzer çalışmalarda yerel alanlar çalışılmıştır. Özellikle son yıllarda yaz aylarında meydana gelen orman yangınları ile gündemde olan Ege ve Akdeniz'in yerel bölgelerinde benzer çalışmalara rastlamak mümkündür. Ancak literatürde tüm ülke çapında ki yangınların mekânsal olarak analizinin yapıldığı, yangın örüntülerinin belirlendiği bir çalışmaya rastlanmamıştır.

Bu çalışmanın amacı, 2000 - 2021 yılları arasında Türkiye sınırları içerisinde meydana gelen 10295 adet bitki örtüsü yangınının mekânsal istatistik yöntemlerle incelenerek yerel ve genel örüntülerinin belirlenmesi ve mekânsal analizinin yapılmasıdır. Oluşturulan yangın veri setine yoğunluk analizi, Global Moran's I, Getis-Ord Gi* Hot Spot Analizi ve Anselin Yerel Moran's I Kümeleme analizi işlemleri gerçekleştirilerek mekânsal örüntülerin tespit edilmesi amaçlanmıştır. Gerçekleştirilen analizler ile elde edilen sonuçlar yardımıyla grafik haritalar üretilmiş ve yorumlanarak sonuç ve öneriler sunulmuştur.

2. Materyal ve Yöntem

2.1 Çalışma alanı

Çalışma alanı olarak Türkiye ülke sınırları seçilmiştir. Türkiye, Afrika, Asya ve Avrupa kıtaları arasında yerleşmiş ve bu üç kıta arasında jeopolitik olarak büyük öneme sahip bir ülkedir. Bundan dolayı birçok canlı türünün kıtalar arası geçişinin yaşandığı doğal bir köprü konumundadır. Bu yapı değişken arazi yapısıyla birleşince zengin bir bitki türü ve bitki toplumu çeşitliliğinin oluşmasına neden olmaktadır. Bu nedenle 11000'e yakın bitki sınıfı doğal yayılışını Türkiye'de yapmakta ve bunların %35'i endemik olarak sınıflanmaktadır (Aksoy vd., 2014). Türkiye'de 5 ana bitki örtüsü tipi hâkimdir. Bunlar; Orman, Maki, Garig, Step ve Alpin tipleridir. Ülkemizde bulunan en önemli bitki örtüsü tiplerinin başında ormanlık alanlar gelmektedir. Değişik yapı ve özellikteki orman bitki örtüsü ülke alanının yaklaşık % 29.4'ünü oluşturur (OGM, 2021). Maki, Akdeniz bölgesindeki iklim şartlarına ve yetişme ortamına uyum sağlamış, sert yapraklı, sık dallı sürekli yeşil 2 m veya daha boylu çalılardan oluşan bitki topluluğudur. Garig (Frigana); Akdeniz flora alanında, toprağın çok taşlı ve sığ olduğu, çok kurak alanlarda antropojen etkilerle maki bitki örtüsünün yerini alan, 0,5-1 m boyunda olan bodur çalılardan oluşur. Step bitki örtüsünde çok yıllık, derin odunsu köklü yapıda, yastık oluşturan bitkiler yaygındır. İç Anadolu, Doğu Anadolu ve Güneydoğu Anadolu bölgelerinin en önemli bitki örtüsü tipidir. Alpin bitki örtüsü, yüksek dağlık kesimlerdeki orman ve ağaç sınırında 1700 - 1800 m'den sonra yastık çalılırları ile otsu bitkilerden oluşur. Ege, Akdeniz, Doğu Anadolu ve özellikle Doğu Karadeniz bölgesindeki yüksek dağlarda, orman sınırından dağların en yüksek kademelerine kadar yayılmaktadır. Türkiye'nin ana vejetasyon tipleri dışında, Anadolu ve Trakya, değişken jeomorfolojik yapıdan ve coğrafik özelliklerinden kaynaklanan, biyolojik çeşitlilik bakımından zengin, nadir özel habitatları içinde barındıran bitki örtüsü tiplerine sahiptir. Bunlar; Longoz, Halofitik, Kıyı kumulları, Kayalık, Riparian, Jipsli alanlar ve Turbalık alanlardır (Aksoy vd., 2014).

Türkiye’de iklim tipi olarak üç farklı türe rastlanmaktadır. Genel anlamda Ege ve Akdeniz kıyılarında Akdeniz iklimi, Karadeniz kıyılarında bir ılıman okyanus iklim tipi olan Karadeniz iklimi ve İç Anadolu Bölgesi, Doğu Anadolu ve Güneydoğu Anadolu bölgeleri gibi iç kesimlerde karasal iklim görülmektedir. Özellikle Akdeniz çevresinde bulunan ülkelerde son yıllarda artış gösteren yangınların en büyük sebebi olarak iklim değişikliği gösterilmektedir. İklim değişikliğine bağlı olarak sıcak hava dalgalarının sıklığının ve şiddetinin artması sonucunda bitki örtüsü yangınlarının görülme sıklığı da artmıştır. İklim değişikliği nedeniyle aşırı kurak koşullara maruz kalan bitki örtüsü içerisindeki nem miktarının iyice azalması daha kolay yanıcı hale gelmesi sonucunu doğurmaktadır (Sarı, 2022; Tavşanoğlu, 2021; Tüfekçioğlu vd., 2022).


2.2 Veriseti

Çalışmada NASA tarafından kontrol edilen Fire Information for Resource Management System (FIRMS) servisinin MODIS platformunun Terra ve Aqua uyduları tarafından tespit edilmiş 11 Kasım 2000’den 31 Aralık 2021 tarihine kadar meydana gelen yangın verileri veri seti olarak kullanılmıştır. MODIS, yangın gözlemi için tasarlanmış spektral ve radyometrik özelliklere ve 1 km'lik konumsal çözünürlüğe sahip uzaktan algılama platformudur. MODIS platformu algılama işlemi, yangınlardan gelen güçlü orta kızılötesi radyasyondan yararlanarak (4– 11 µm elektromanyetik spektrum kanallarından) elde edilen parlaklık sıcaklıklarına dayanan, daha küçük ve soğuk yangınlara duyarlılığı artıran ve yanlış alarmların oluşumunu azaltan bağlamsal bir algoritma kullanarak gerçekleştirir (Fornacca vd., 2017; Giglio vd., 2016, Giglio vd., 2018; İban ve Şekertekin, 2022; Oom ve Pereira, 2013).


Veri seti içerisindeki tablo bilgilerinde; yangının konumu, Kelvin değeri cinsinden sıcaklık değeri, verinin elde edildiği gün ve saat bilgisi, hangi uydudan elde edildiği, verinin yüzde cinsinden güven (confidence) değeri, megawatt cinsinden yangın ışınimsal güç (fire radiative power) değeri, yangının türü ve gece veya gündüz meydana geldiği bilgisi bulunmaktadır. Coşkuner (2022) ve Giglio vd. (2016), çalışmalarında NASA-FIRMS tarafından yayınlanan MODIS yangın verilerinin çok büyük bölümünün tarım alanlarından yanlış alarm olarak geldiğini ve yanlış değerlendirildiklerini belirtmektedirler. Bu nedenle çalışmada kullanılan yangın verileri için 4 aşamalı bir filtreleme işlemi gerçekleştirilmiştir. Yangın verileri ilk olarak tablo bilgilerinde bulunan yangın türü varsayılan bitki örtüsü yangınına (type=0) göre filtrelenmiştir. İkinci ve en önemli filtreleme işlemi olarak; yangın verileri CORINE 2000, 2006, 2012 ve 2018 arazi örtüsü/kullanımı verilerinde bitki örtüsü sınıfları ile çakışmalarına göre filtrelenmiştir. Böylece tarım arazilerine (anız yangınları vb.) denk gelen yangın noktalarının eliminasyonu sağlanmıştır. Ayrıca bitki örtüsüne denk gelen yangın verileri de kendi içerisinde gruplandırılmıştır. Bu gruplandırma işlemi CORINE arazi örtüsü verilerinde belirtilen ormanlık alanlara (311: Broad-leaved, 312: Coniferous, 313: Mixed, 323: Sclerophyllous ve 324: Transitional woodland shrub) ve otlak alanlara (321: Natural grassland, 322: Moors and heathland ve 333: Sparsely vegetated) göre yapılmıştır. Her bir CORINE verisine denk gelen aralıklardaki yangın verileri (2000 yılı CORINE verisi için 2000 - 2005 yılı, 2006 yılı CORINE verisi için 2006 - 2011 yılı, 2012 yılı CORINE verisi için 2012 - 2017 yılı ve 2018 yılı CORINE verisi için 2018 - 2021 yıllarına ait yangınlar) ormanlık ve otlak alanlara denk gelmelerine göre gruplandırılmıştır. Sonrasında Tablo 1’de gösterilen piksel güven sınıfları eşik değerlerinden nominal güven sınıfı ve üzeri (%30 ve üzeri) yangınların seçimi yapılmıştır. Son olarak ise özellikle Ege ve Akdeniz bölgesinde bulunan aynı tarihli ve benzer konuma kümelenmiş yangın noktaları yangın ışınimsal gücüne (FRP değeri) göre genelleştirilerek filtrelenmiştir. Filtreleme işlemi sonrası 22 yıllık süreç içerisinde Türkiye sınırları içerisinde 10,295 adet yangın nokta verisi veri seti olarak elde edilerek yapılan analizlerde kullanılmıştır (Şekil 1). Yangın sayılarının yıllara göre dağılımı ise Şekil 2’de gösterilmektedir.

Tablo 1. Eşik değerlerine göre yangın piksel güven sınıfları

| Aralık | Güven Sınıfı |
|----------------------------|--------------|
| $\% 0 \leq C < \% 30$ | Düşük |
| $\% 30 \leq C < \% 80$ | Nominal |
| $\% 80 \leq C \leq \% 100$ | Yüksek |



Şekil 1. Çalışma alanı ve yangın nokta konumları

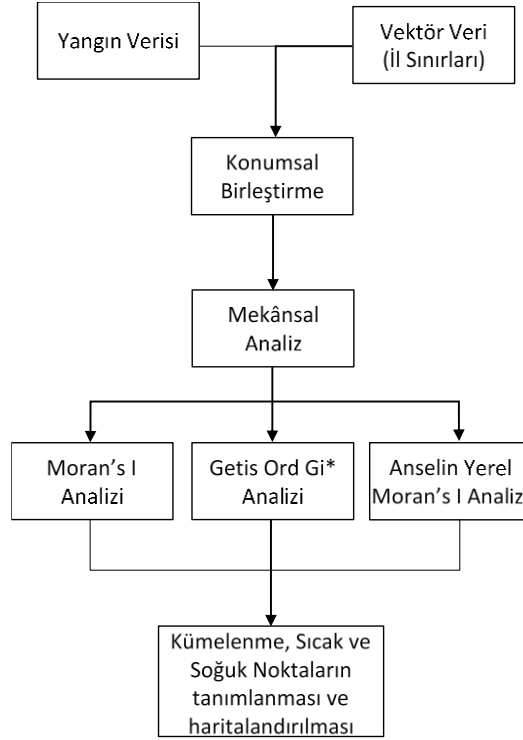


Şekil 2. Yıllara göre yangın sayıları

2.3 Yöntem

Mekânsal otokorelasyon bir konumda bulunan veri noktasının komşu konumlarda bulunan veriler ile bağımlı olup olmadığını belirlemek amacıyla kullanılır. Mekânsal otokorelasyon pozitif ya da negatif olabilir. Pozitif değerler komşu konumlardaki özelliklerin doğrusal olarak birbirlerini etkilediğini gösterirken (kümelenme), negatif değerler ise komşu konumlardaki özelliklerin ters olarak birbirlerini etkilediğini (dağılma) göstermektedir (Erdoğan, 2010). Çalışmada ilk olarak illere göre bitki örtüsü yangınlarının dağılımları ve yoğunlukları tespit edilmiştir. Yangın verileri yıl yıl tablolar şeklinde indirildikten sonra birleştirilmiş ve konum bilgilerinden yararlanılarak tüm yangın bilgilerini içeren tek bir özellik sınıfına aktarılmıştır. Filtreleme işlemi sonrasında yangın noktaları ve il sınırları vektör verisi, ortak bir projeksiyona sahip olabilmesi için dönüşüm işlemi gerçekleştirilmiş ve her bir il için yangın yoğunluk değeri hesaplanmıştır.

Yangın yoğunlukları belirlendikten sonra meydana gelen bu yangınlar arasında mekânsal korelasyon olup olmadığı araştırılmıştır. Bunun için Moran's I yöntemi kullanılmış ve yangınlar arasındaki örüntüler tespit edilmiştir. Moran's I yöntemi hem özellik konumlarına hem de özellik değerlerine göre mekânsal otokorelasyonu aynı anda ölçebilme yeteneğine sahiptir. Çalışma içerisindeki tüm analizlerde ArcGIS 10.7 yazılımından faydalanılmış ve uygulanan iş akış şeması Şekil 3'te gösterilmiştir.



Şekil 3. İş akış şeması

2.3.1 Moran's I Analizi

Moran's I analizi, veri seti olarak kullanılan noktaların genel uzamsal otokorelasyonunu ölçer ve veri noktaları arasındaki örüntüleri tanımlayama yardımcı olur. Analiz belirli bir nokta örüntüsü için konumsal otokorelasyon veya dağılım derecesini göstermektedir (Affan vd., 2016; Al-Ahmadi vd., 2013; Cheruiyot, 2022).

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} z_i z_j}{S_0 \sum_{i=1}^n z_i^2} \quad (1)$$

n toplam özellik sayısını, z_i i inci özneliğin ortalama değerinden olan sapmayı, w_{ij} i ve j inci değerler arasındaki konumsal ağırlığı ve S_0 tüm ağırlık değerlerinin toplamını temsil etmektedir.

Moran yönteminde I indeks, z skoru ve p değerleri hesaplanır. Hesaplanan I indeks değeri -1 ile +1 arasında değer alabilir. z skoru ve p değeri sıfır hipotezinin mekânsal rasgele modelini reddetme olasılığını belirlemek için kullanılırlar. -2.58'den küçük veya 2.58 den büyük çıkan z skoru ile %99'un üzerinde 0.01 güven düzeyine sahip p değeri sıfır hipotezinin reddedildiğini ve verilerin kümelenildiğini göstermektedir.

Analiz yöntemi veri noktalarının kümelenme, dağınık ve rasgele olma durumunu belirler. Eğer Moran's I indeks değeri sıfırdan büyükse (pozitif değerler), veri noktaları kümelenmiştir. Eğer indeks değeri sıfırdan küçükse (negatif değerler), veri noktaları dağınık durumdadır. Eğer indeks değeri sıfıra çok yakın veya sıfırsa, veri noktaları rasgele dağılmıştır (Chen ve Yang, 2018; Cheruiyot, 2022; Ohshima vd., 2022).

2.3.2 Getis-Ord G_i^* yöntemi

Bu yöntem Art Getis and Keith Ord tarafından 1995 yılında geliştirilmiştir. Getis-Ord G_i^* yöntemi özelliklerin tam uzamsal rastgelelik içinde yapılandırıldığı sıfır hipotezini reddetmek veya reddetmemek için z -skorlarını ve p değerlerini tahmin eden bir analiz yürütmektedir.

Yöntem ile birlikte istatistiksel olarak hesaplanan z skoru ne kadar büyük ise veri seti içerisinde bulunan yüksek değerler o derecede kümelenmişlerdir. Öte yandan hesaplanan z skoru ne kadar küçükse veri setindeki düşük değerler o oranda fazla kümelenmişlerdir (Feng vd., 2018; Rossi ve Becker, 2019; Zhang vd., 2022). Hesaplanan G_i^* değeri sıfıra yaklaştığında hesaplanan özelliğin komşuluğunda yüksek veya düşük değerlerin olmadığından bahsedilebilir.

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

x_j veri setindeki j inci özelliğin değerini, $w_{i,j}$, i inci ve j inci veri noktaları arasındaki konumsal ağırlık değerini ve S ise standart sapmayı tanımlamaktadır.

2.3.3 Anselin Yerel Moran's I Analizi

Moran's I yöntemi genel ölçekli olup veri setinin genel dağılımının konumsal bağımlılık düzeyini ölçmek için kullanılmaktadır. Ancak veri seti içerisinde dağılımın hangi bölgelerde kümelenmiş yerel olarak belirlenmemektedir. Anselin Yerel Moran's I yöntemi değişkenlerin birbirine benzeyip ve benzemediğini belirlemek için kullanılan yerel bir yöntemdir. Yerel Moran's I işleminden elde edilen sonuçlar, atanan sınıfının çözüm alanı içindeki her gözlemin konumunu görüntüleyen bir Moran dağılım grafiğinde görselleştirilir. Dağılım grafiği içinde, Yerel Moran's I değeri, her kategorinin iki boyutlu çözüm uzayı içindeki i . gözleminin göreceli konumunu tanımlar. Tüm Moran's I değerlerinin belirli bir güven düzeyi içerisinde uzamsal ilişkinin anlamlı olup olmadığını belirlemek için her nokta için bir anlamlılık testi hesaplanmaktadır. Pozitif bir değer alan Yerel Moran's I değeri, komşu noktalar ile benzer şekilde yüksek veya düşük değerlere sahip olan konumu ifade etmektedir. Bu konum uzamsal küme olarak adlandırılır. Öte yandan, negatif bir yerel Moran's I değeri, çevresindeki konumların değerlerinden farklı olan potansiyel bir uzamsal aykırı değeri göstermektedir. Analiz sonucunda elde edilen Z skoru değeri istatistiksel anlamlılık hakkında bilgi vermektedir (Anselin, 1995; Bone vd., 2013; Yakar, 2011; Yuan vd., 2018). Anselin Yerel Moran's I aşağıdaki şekilde tanımlanır;

$$I_i = \frac{x_i - \bar{X}}{S_i^2} \sum_{j=1, j \neq i}^n w_{i,j} (x_j - \bar{X}) \quad (3)$$


x_i veri setindeki i . özelliğin değeri, \bar{X} ilgili değerlerin ortalaması (deprem büyüklüklerinin ortalaması), $w_{i,j}$, i inci ve j inci veri noktaları arasındaki ağırlık değerini temsil etmektedir.

$$S_i^2 = \frac{\sum_{j=1, j \neq i}^n (x_j - \bar{X})^2}{n-1} \quad (4)$$

buradaki n toplan özellik sayısını temsil etmektedir. Farklı komşuluk kriterlerine bağlı olarak tanımlanabilen ve tüm noktalar arasındaki rölatif konum ölçüsünü veren bir konumsal ağırlık matrisi olarak düşünülebilir.

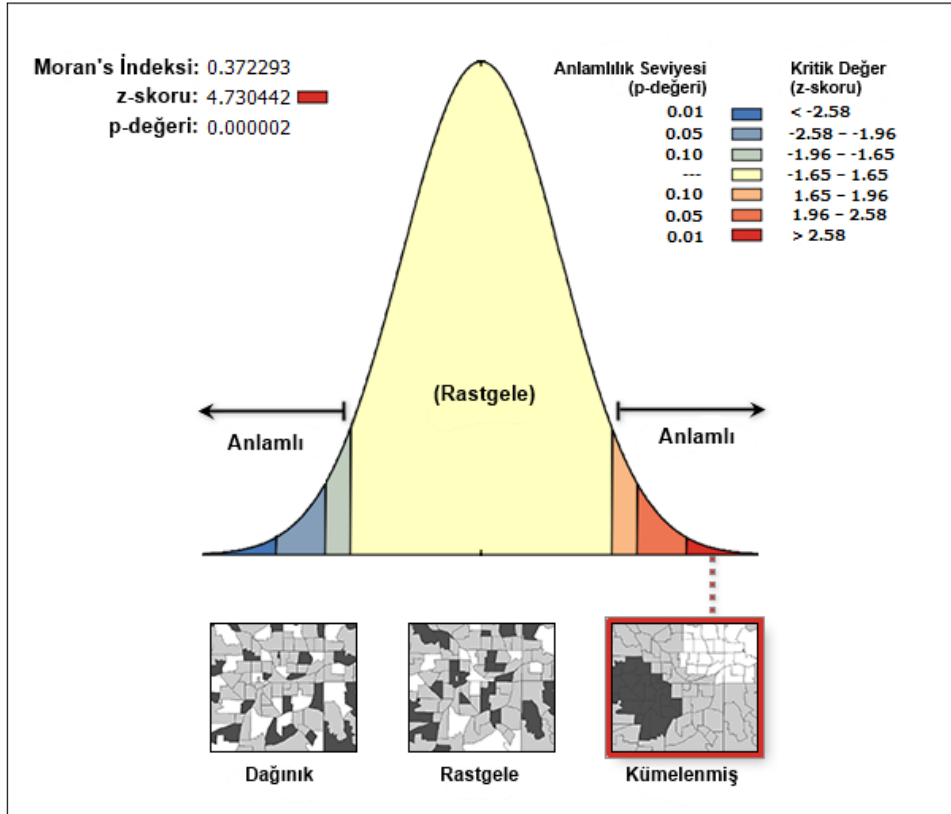
3. Bulgular

Ormanlık ve otlak alanlara ait yangın verisi ile il sınırlarına ait veri konumsal olarak birleştirilerek (spatially join) hangi ilde kaç adet hangi tür yangının meydana geldiği tespit edilmiştir. İl sınırları içerisine düşen yangın sayılarının belirlenmesinden sonra her bir yangın sayısı ilin yüzölçümü ile normalize edilerek yangın yoğunluk haritası oluşturulmuştur (Şekil 4). Şekil 4'te ormanlık alanlara ait yangın sayıları haritası incelendiğinde en yoğun ormanlık alan yangınına maruz kalan iller Antalya, Muğla, İzmir, Hatay, Şırnak ve Hakkâri olduğu görülmektedir. Orman yangınlarının genellikle Akdeniz ormanlarının bulunduğu sahil şeridindeki illerde yoğunlaştığı görülmektedir. Otlak alanlara ait yangın sayıları incelendiğinde ise en yoğun otlak alanlar yangınına maruz kalan iller Şanlıurfa, Mardin, Batman, Siirt, Şırnak, Hakkâri, Kırıkkale ve Kırşehir olarak sıralanmaktadır. Ayrıca otlak yangınları haritası incelendiğinde genel olarak İç Anadolu ve Güneydoğu Anadolu bölgesinde yoğunluk olduğu göze çarpmaktadır.



Şekil 4. İllerin ormanlık (üst) ve otlak (alt) alanlara göre yangın sayısı dağılımları

Veri seti içerisinde bulunan özelliklerin kümelenmiş, dağılmış ve rastgele olup olmadığı hakkında bilgi vermektedir. Yukarıda oluşturulan yoğunluk haritasındaki değerler kullanılarak gerçekleştirilen Moran's I analizinin sonucu Şekil 5'te gösterilmektedir.

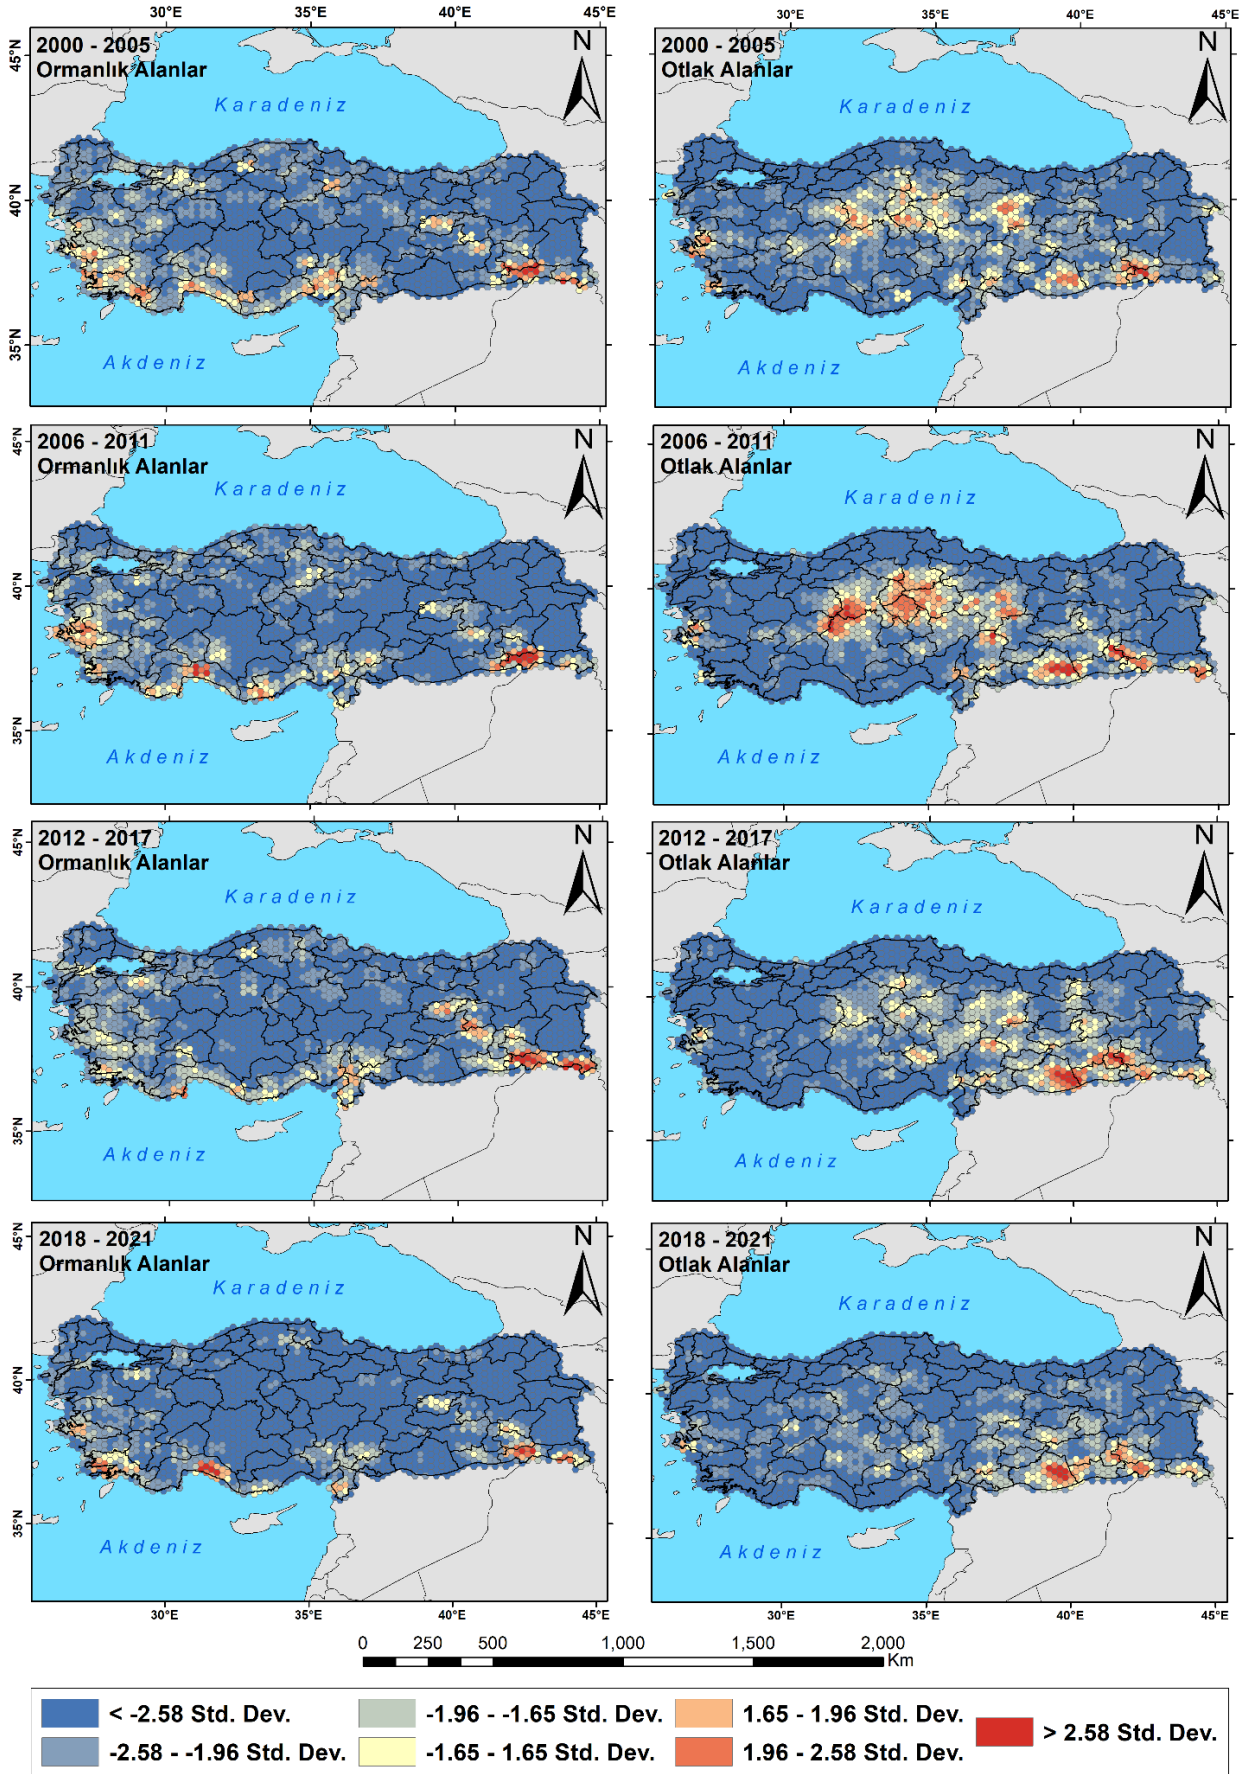


Şekil 5. Moran's I indeks değerleri

Yapılan analiz sonucunda Moran's indeks değeri 0.372293 olarak belirlenmiştir. Moran's I indeks değerinin sıfırdan yüksek çıkması +1 değerine yakın olduğunu ve kullanılan veriler arasında mekânsal otokorelasyonun bulunduğunu göstermektedir. Analiz sonucunda z skoru ise 4.730442 olarak hesaplanmıştır. z skorunun kritik değerden yüksek çıkması verilerin kümelendiğini göstermektedir.

Moran's I analizi ile verilerin kümeleneip kümelendiğinin belirlenmesinden sonra Getis Ord G_i^* analizi gerçekleştirilerek çalışma alanı içerisindeki sıcak ve soğuk noktalar belirlenmiştir. İlk olarak Türkiye sınırları konumsal ölçekteki sorunlarla başa çıkmak için altigenlere (hexel) bölünmüştür. Altigen şekil, veri dağılımını daha doğru bir şekilde modellemesi, dikdörtgen modellere göre daha az belirsizlik içermesi ve verilerin görsel olarak anlaşılması için temel bir altlık sağlaması nedeniyle seçilmiştir (Aftergood ve Flannigan, 2022). En uygun altigen boyutunu bulmak için çeşitli ön analizler (komşuluk analizleri vb.) gerçekleştirilmiştir. Yapılan ön analizler sonucunda 25 km'lik altigen boyutunun gerçekleştirilecek mekânsal analizler için en uygun boyut olduğuna karar verilmiştir. Boyut belirlendikten sonra çalışma alanında altigen vektör ızgarası oluşturulmuş ve her bir altigenin içerisine düşen yangın nokta sayısı belirlenmiştir. Getis-Ord G_i^* sıcak ve soğuk nokta analizi ile Anselin Yerel Moran's I analizleri için oluşturulan altigen vektör ızgara verisi kullanılmıştır.

Getis Ord G_i^* yöntemiyle oluşturulan haritalar Şekil 6'da gösterilmektedir. Şekil 6'da sol sütunda bulunan haritalar ormanlık alanların, sağ sütunda bulunan haritalar ise otlak alanların farklı dönemlere göre sıcak ve soğuk noktalarını göstermektedir. Buna göre ormanlık alanlardaki sıcak noktalar yoğunlukla Ege ve Akdeniz sahil şeridi ile Şırnak ili genelinde gözlemlenmektedir. Özellikle 2006 - 2011 ve 2018 - 2021 yılları arasında Antalya'da meydana gelen büyük çaplı orman yangınları sebebiyle bu bölgedeki sıcak noktaların varlığında atış göze çarpmaktadır. 21 yıllık süreç içerisinde Güneydoğu Anadolu bölgesindeki özellikle Şırnak ve Hakkâri'deki sıcak nokta örüntülerinin son yıllarda azalma eğiliminde olduğu, buna karşın Akdeniz bölgesindeki yangınların özellikle Muğla, İzmir ve Antalya'da meydana gelen yangınların ise artış gösterdiği görülebilmektedir. Belirtilen bu gölgelerin dışında çeşitli lokal küçük bölgelerde de (Bursa, Sakarya ve Tunceli gibi) sıcak noktalardan söz etmek mümkündür. Otlak alanlar incelendiğinde ise sıcak noktaların genellikle İç Anadolu ile Güneydoğu Anadolu bölgesinde yoğunlaştığı görülmektedir. 2000 - 2011 yılları arasındaki dönemde otlak alan yangınlarına ait sıcak noktaların Ankara'nın güneyi ile Konya'nın kuzeyinde, Kırıkkale, Kırşehir ve Yozgat genelinde, Şanlıurfa, Şırnak, Siirt, Batman ve Hakkâri genelinde yoğunlaştığı görülmektedir. 2011 yılı sonrasında ise otlak alan yangınları İç Anadolu bölgesindeki etkinliğini azalttığı, ancak Güneydoğu Anadolu bölgesinde (özellikle Şanlıurfa'da) devamlılık gösterdiği görülmektedir. Yukarıda bahsedilen alanların dışında kalan alanlar, her iki bitki örtüsü tipi yangını içinde soğuk noktalar olarak belirlenmiştir.



Şekil 6. Getis Ord Gi* yöntemine göre ormanlık ve otlak alanlarda oluşan sıcak ve soğuk noktalar

Son olarak Anselin Yerel Moran's I yöntemi ile Kümelenme ve Aykırı Değer Analizi (Cluster and Outlier Analysis) gerçekleştirilmiştir. Bu yöntemde veri seti içerisindeki birbirine benzeyen ve benzemeyen değişkenlerin durumları incelenmektedir. Bitki örtüsü yangını gibi veri setleri incelenirken bu yöntem, yangın faaliyetlerinin düşük olduğu alanlarla çevrili yüksek yangın faaliyeti olan alanların veya bunun tam tersinin bulunmasına yardımcı olan etkili bir araçtır. Anselin Yerel Moran's I analizleri sonucunda ormanlık ve otlak alanlar için oluşturulan haritalar Şekil 7'de gösterilmektedir. Kırmızı ve mavi olan bölgeler aykırı (Outlier) değerlerdir. Mavi olan bölgeler, yangın aktivitesinin yüksek olduğu alanlara yakın olan düşük yangın faaliyet bölgelerinin temsil etmektedir. Analiz sonrasında mavi renkli bölgelerin, yani yüksek yangın yoğunluğuna komşu düşük yangın yoğunluğu noktalarının, orman yangınları için özellikle Ege, Akdeniz ve Güneydoğu Anadolu bölgelerinde bulunduğu görülmektedir. Otlak alanlar için ise mavi bölgeler genellikle İç ile Güneydoğu Anadolu bölgesinde yoğunlaştığı görülmektedir. Kırmızı renk orman yangını aktivitesinin düşük olduğu bölgelerin yakınında, yüksek orman yangın faaliyeti olan bölgeleri göstermektedir. Türkiye'de her iki bitki örtüsü tipi için bu sınıfa giren kümelenmiş olmasa da, çeşitli alanların varlığı tespit edilmiştir. Güneydoğu Anadolu bölgesi hariç her bölgede bu sınıfa giren alanların var olduğu görülmektedir. Şekil 7'ye göre pembe renk ile gösterilen yüksek yangın faaliyetlerinin yanında yine yüksek yangın faaliyetinin olduğu alanlar, ormanlık alanlar için İzmir, Muğla, Şırnak ve Hakkâri illerinde kümelenildiği görülmektedir. Otlak alanlar için ise Ankara, Kırşehir, Kırıkkale, Çorum, Şanlıurfa, Batman, Şırnak ve Hakkâri'de kümelenmeler gösterdiği tespit edilmiştir. Turkuaz renk ile temsil edilen düşük yangın faaliyetlerinin yanında yine düşük yangın faaliyetlerinin ise Türkiye'nin herhangi bir yerinde görülmediği tespit edilmiştir (Şekil 7).

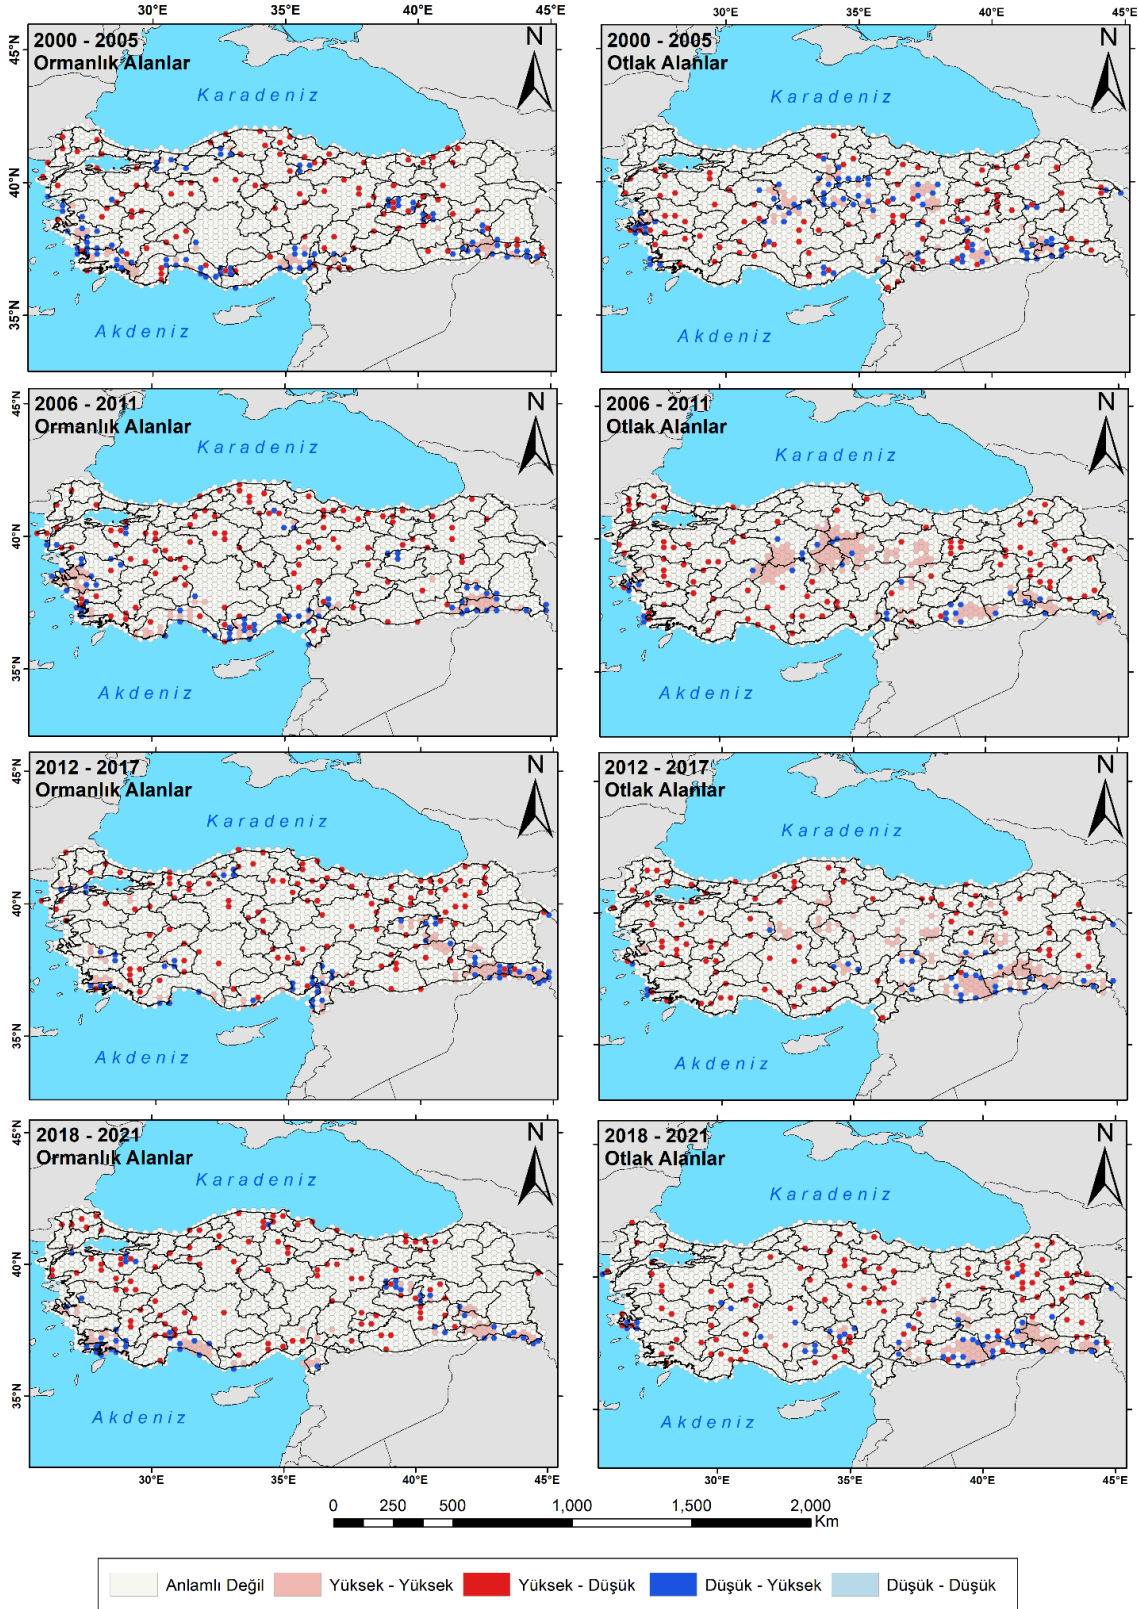
4. Tartışma

2000-2021 yılları arasında Türkiye'de meydana gelen bitki örtüsü yangınlarının mekânsal otokorelasyonunu ve kümelenmelerini incelemek için bu çalışmada Moran's I, Getis-Ord G_i^* ve Anselin Yerel Moran's I analizleri kullanılmıştır. Oom ve Pereira (2013), çalışmalarında Moran's I analizinin pozitif değerlerine göre MODIS yangın verilerinin yüksek mekânsal otokorelasyona sahip olduğunu belirtmişlerdir. Ayrıca Barreal ve Loureiro, (2015), Moran's I ve LISA istatistiklerini kullanarak Galiçya orman yangınlarının oluşumundaki mekânsal bağımlılığı ortaya çıkarmıştır. Karabacak vd. (2019), Antalya'da meydana gelen yangınların mekânsal otokorelasyonlarını Moran's I ve Anselin yerel Moran's I yöntemleri ile inceleyerek risk analizi gerçekleştirmişlerdir. Mevcut çalışmada da yangın verilerinin otokorelasyonları Moran's I analizi ile araştırılmış ve verilerin diğer çalışmalarda olduğu gibi kümelenildiği, yani mekânsal otokorelasyona sahip olduğu tespit edilmiştir. Mekânsal otokorelasyon bilgisi elde edildikten sonra bu kümelerin bölgeleri incelenmiş ve Getis-Ord G_i^* yöntemi ile sıcak ve soğuk nokta bölgeleri altıgen (hexel) vektör ızgara formuyla incelenmiştir. Aftergood ve Flannigan (2022), Bae vd. (2015), Chen ve Yang (2018), Duran (2014), Gajovic ve Todorovic (2013), Ma vd. (2022) ve Visner vd. (2021) Getis Ord G_i^* sıcak nokta analizini kullanarak bu yöntemin orman yangınlarının analizinde kullanılabilirliğini göstermiştir. Son olarak Anselin Yerel Moran's I yöntemi kullanılarak yerel otokorelasyonlar belirlenmiştir. Bu analize göre, çalışma alanında yangın yoğunluğunun yüksek olduğu ve bunun tersi olan alanların çevresinde yüksek ve düşük yoğunluklu alanlar belirlenmiştir. Gajovic ve Todorovic (2013), Gayır ve Arslan (2018) ve Karabacak vd. (2019) bu çalışma gibi yerel ölçekte yangın kümelerinin birbirlerine davranışlarını incelemek için bu yöntemi uygulamışlardır. Kullanılan analiz teknikleri sonucunda meydana gelen yangınların kümelenildiği ve aralarında konumsal bir ilişkinin var olduğu literatürdeki birçok çalışmada olduğu gibi bu çalışmada da tespit edilmiştir.

5. Sonuçlar

Bu çalışmada 2000 ile 2021 yılları arasında Türkiye'de ormanlık ve otlak bitki örtüsü alanlarında meydana gelen yangınların mekânsal analizi ve otokorelasyonları incelenmiştir. Çalışmada veri seti olarak MODIS uzaktan algılama platformunun Aqua ve Terra uyduları ile tespit edilmiş olan 10295 adet bitki örtüsü yangını veri seti olarak kullanılmıştır. Veri setini analiz etmek için çeşitli mekânsal istatistik araçları kullanılmıştır. Bunlar; Moran's I mekânsal otokorelasyon analizi, Getis-Ord G_i^* analizi, Anselin Yerel Moran's I analizidir.

CBS ve UA afetlerin izlenmesinde birlikte kullanılması etkin, doğru ve hızlı sonuçların elde edilmesine olanak sağlamaktadır. CBS ve UA sistemlerinin yangınlar üzerinde birlikte kullanılması olumsuz ve zaman zaman yıkıcı sonuçlar doğuran bu doğal afet türüne karşı önlem alabilmek adına gerekli olan iki araçtır. CBS ile konumsal olarak analiz edilen yangınların örüntülerinin belirlenmesi; – hangi yönde yayılım gösterdiği, meydana gelme periyodu vb.– yapılacak olan afet planlama ve yönetimi çalışmalarında karar vericilere önemli bir bilgi kaynağı oluşturacaktır. Geleceğe yönelik alınacak kararlarda ortaya çıkarılan sonuçlar doğrultusunda adımlar atmak yangın riski bakımından yüksek olan bölgeler üzerinde yaşayanlar için olası zararların azaltılması açısından önemli olacaktır.



Şekil 7. Anselin Yerel Moran's I analizine göre ormanlık ve otlak alanlara ait kümelenme ve aykırı değerler

Teşekkür

Yazar, MODIS platformunun Terra ve Aqua uyduları ile yangın noktasal verilerini sağlayan NASA FIRMS servisine teşekkür eder.

Kaynaklar

- Affan, M., Syukri, M., Wahtuna, L., & Sofyan, H. (2016). Spatial Statistic Analysis of Earthquakes in Aceh Province Year 1921-2014: Cluster Seismicity. *Aceh International Journal of Science and Technology*, 5(2), 54-62.
- Aftergood, O. S. R., & Flannigan, M. D. (2022). Identifying and analyzing spatial and temporal patterns of lightning-ignited wildfires in Western Canada from 1981 to 2018. *Canadian Journal of Forest Research*, 52, 1399-1411.
- Aksoy, N., Tuğ, G. N., & Eminağaoğlu, Ö. (2014). Türkiye'nin Vejetasyon Yapısı. In Ü. Akkemik (Eds.), *Türkiye'nin Doğal-Egzotik Ağaç ve Çalıları-I* (pp. 54-68), Ankara: Orman Genel Müdürlüğü Yayınları.
- Al-Ahmadi, K., Al-Amri, A., & See, L. (2013). A Spatial Statistical Analysis of the occurrence of earthquakes along the Red Sea floor spreading: Clusters of Seismicity. *Arabian Journal of Geosciences*, 7(7), 2893-2904.
- Anselin, L. (1995). Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93-115.
- Arca, D., Hacısalıhoğlu, M., & Kutoğlu, H. (2020). Producing forest fire susceptibility map via multi-criteria decision analysis and frequency ratio methods. *Natural Hazards*, 104(1), 73-89.
- Arslantürk, N. (2007). Yangının vejetasyon üzerine etkisi. *Selçuk Üniversitesi Fen Fakültesi Fen Dergisi*, 29(2), 141-153.
- Bae, G., Jung, Y., & Yoo, H. (2015). An analysis on the characteristics of spatial clustering distribution in the urban fire of Gyeongsangnam-do, Korea. In *ACRS 2015 - 36th Asian Conference on Remote Sensing: Fostering Resilient Growth in Asia, 2015. Proceedings*. (pp. 4597-4603). Asian Association on Remote Sensing.
- Barreal, J., & Loureiro, M. L. (2015). Modelling spatial patterns and temporal trends of wildfires in Galicia (NW Spain). *Forest Systems*, 24(2), e022. doi: 10.5424/fs/2015242-05713.
- Bone, C., Wulder, M. A., White, J. C., Robertson, C., & Nelson, T. A. (2013). A GIS-based risk rating of forest insect outbreaks using aerial overview surveys and the local Moran's I statistic. *Applied Geography*, 40, 161-170.
- Busico, G., Giuditta, E., Kazakis, N., & Colombani, N. (2019). A hybrid GIS and AHP approach for modelling actual and future forest fire risk under climate change accounting water resources attenuation role. *Sustainability*, 11(24), 7166. doi: 10.3390/su11247166.
- Chen, C. Y., & Yang, Q. H. (2018, March). Hotspot analysis of the spatial and temporal distribution of fires. In *4th International Conference on Geographical Information Systems Theory, Applications and Management (GISTAM 2018)*. Proceedings. (pp. 15-21).
- Cheruiyot, K. (2022). Detecting spatial economic clusters using kernel density and global and local Moran's I analysis in Ekurhuleni metropolitan municipality, South Africa. *Regional Science Policy and Practice*, 14(2), 307-327.
- Çetin, M., Isik Pekkan, Ö., Ozenen Kavlak, M., Atmaca, I., Nasery, S., Derakhshandeh, M., & Cabuk, S. N. (2022). GIS-based forest fire risk determination for Milas district, Turkey. *Natural Hazards*. doi: 10.1007/s11069-022-05601-7.
- Çolak, E., & Sunar, F. (2020a). Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes region, İzmir. *International Journal of Disaster Risk Reduction*, 45, 101479. doi: 10.1016/j.ijdrr.2020.101479.
- Çolak, E., & Sunar, F. (2020b). Spatial pattern analysis of post-fire damages in the Menderes District of Turkey. *Frontiers of Earth Science*, 14(2), 446-461.
- Coşkuner, K. A. (2022). Assessing the performance of MODIS and VIIRS active fire products in the monitoring of wildfires: a case study in Turkey. *IForest*, 15(2), 85-94.
- Duran, C. (2014). Mersin ilindeki orman yangınlarının başlangıç noktalarına göre mekânsal analizi (2001-2013). *Ormanlık Araştırma Dergisi*, 1(1A), 38-49.
- Erdoğan, S. (2010). Epidemiyolojide CBS Uygulamaları: Konumsal Kümeleme Yöntemlerinin Karşılaştırılması-Menenjit Örneği. *Harita Teknolojileri Elektrik Dergisi*, 2(2), 23-31.
- Feng, Y., Chen, X., Gao, F., & Liu, Y. (2018). Impacts of changing scale on Getis-Ord Gi* hotspots of CPUE: a case study of the neon flying squid (*Ommastrephes bartramii*) in the northwest Pacific Ocean. *Acta Oceanologica Sinica*, 37(5), 67-76.
- Fornacca, D., Ren, G., & Xiao, W. (2017). Performance of Three MODIS fire products (MCD45A1, MCD64A1, MCD14ML), and ESA Fire_CCI in a mountainous area of Northwest Yunnan, China, characterized by frequent small fires. *Remote Sensing*, 9(11), 1131. doi: 10.3390/rs9111131.
- Gajovic, V., & Todorovic, B. (2013). Spatial and temporal analysis of fires in Serbia for period 2000-2013. *Journal of the Geographical Institute Jovan Cvijic, SASA*, 63(3), 297-312.
- Gayır, B., & Arslan, O. (2018). Orman Yangınlarının CBS Tabanlı Konumsal İstatistik Analizi: 2011 -2015 Yılları Arasında Muğla Orman Bölge Sınırları İçerisinde Çıkan Yangınlar. *Anadolu Orman Araştırmaları Dergisi*, 4(1), 44-60.
- Giglio, L., Boschetti, L., Roy, D. P., Humber, M. L., & Justice, C. O. (2018). The Collection 6 MODIS burned area mapping algorithm and product. *Remote Sensing of Environment*, 217, 72-85.
- Giglio, L., Schroeder, W., & Justice, C. O. (2016). The collection 6 MODIS active fire detection algorithm and fire products. *Remote Sensing of Environment*, 178(2016), 31-41.
- Gökkaya, K. (2022). Burned Area and Fire Severity Prediction of a Forest Fire Using a Sentinel 2-Derived Spectral Index

- in Çanakkale, Turkey. *Turkish Journal of Bioscience and Collections*, 6(2), 37-44.
- İban, M. C., & Sekertekin, A. (2022). Machine learning based wildfire susceptibility mapping using remotely sensed fire data and GIS: A case study of Adana and Mersin provinces, Turkey. *Ecological Informatics*, 69, 101647. doi: 10.1016/j.ecoinf.2022.101647.
- İban, M. C., & Şahin, E. (2022). Monitoring burn severity and air pollutants in wildfire events using remote sensing data: the case of Mersin wildfires in summer 2021. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 12(2), 487-497.
- Karabacak, K., Türkşen, Ö., & Bayar, R. (2019, June). Spatial statistics analysis of forest fires in Antalya province. In *1st Istanbul International Geography Congress, 2019. Proceedings*. (pp. 615-630). Istanbul: Istanbul University Press.
- Ma, C., Pu, R., Downs, J., & Jin, H. (2022). Characterizing Spatial Patterns of Amazon Rainforest Wildfires and Driving Factors by Using Remote Sensing and GIS Geospatial Technologies. *Geosciences*, 12(6), 237. doi: 10.3390/geosciences12060237.
- Novo, A., Fariñas-álvarez, N., Martínez-Sánchez, J., González-Jorge, H., Fernández-Alonso, J. M., & Lorenzo, H. (2020). Mapping forest fire risk—a case study in Galicia (Spain). *Remote Sensing*, 12(22), 3705. doi: 10.3390/rs12223705.
- OGM. (2021, Kasım 2). *2020 Türkiye Orman Varlığı*. Retrieved from <https://www.ogm.gov.tr/tr/ormanlarimiz-sitesi/TurkiyeOrmanVarligi/Yayinlar/2020%20T%C3%BCrkiye%20Orman%20Varl%C4%B1%C4%9F%C4%B1.pdf>
- Ohyama, T., Hanyu, K., Tani, M., & Nakae, M. (2022). Investigating crime harm index in the low and downward crime contexts: A spatio-temporal analysis of the Japanese Crime Harm Index. *Cities*, 130, 103922. doi: 10.1016/j.cities.2022.103922.
- Oom, D., & Pereira, J. M. C. (2013). Exploratory spatial data analysis of global MODIS active fire data. *International Journal of Applied Earth Observation and Geoinformation*, 21(1), 326-340.
- Rossi, F., & Becker, G. (2019). Creating forest management units with Hot Spot Analysis (Getis-Ord Gi*) over a forest affected by mixed-severity fires. *Australian Forestry*, 82(4), 166-175.
- Sarı, F. (2021). Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Turkey: A comparative analysis of VIKOR and TOPSIS. *Forest Ecology and Management*, 480, 118644. doi: 10.1016/j.foreco.2020.118644
- Sarı, F. (2022). Identifying anthropogenic and natural causes of wildfires by maximum entropy method-based ignition susceptibility distribution models. *Journal of Forestry Research*. doi: 10.1007/s11676-022-01502-4.
- Sivrikaya, F., & Küçük, Ö. (2022). Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region. *Ecological Informatics*, 68, 101537. doi: 10.1016/j.ecoinf.2021.101537.
- Tariq, S., ul-Haq, Z., Mariam, A., Mehmood, U., & Ahmed, W. (2022). Assessment of air quality during worst wildfires in Mugla and Antalya regions of Turkey. *Natural Hazards*, 115, 1235-1254.
- Tavşanoğlu, Ç. (2017). Yangın Coğrafyası: Vejetasyon Yangınlarının ve Ekolojik Sonuçlarının Alansal Dağılımı. *Kebikeç (İnsan Bilimleri İçin Kaynak Araştırmaları Dergisi)*, 43, 289-300.
- Tavşanoğlu, Ç. (2021). *Akdeniz Bölgesindeki Büyük Orman Yangınlarının Sebepleri ve Yangın Sonrası Yapılması Gerekenler*. Teknik Rapor, Hacettepe Üniversitesi, Ankara.
- Trucchia, A., Meschi, G., Fiorucci, P., Gollini, A., & Negro, D. (2022). Defining Wildfire Susceptibility Maps in Italy for Understanding Seasonal Wildfire Regimes at the National Level. *Fire*, 5(1), 30. doi: 10.3390/fire5010030.
- Tüfekçioğlu, İ., Ergan, G., Kaynaş, B., Aktepe, N., & Tavşanoğlu, Ç. (2022). Akdeniz iklim bölgesindeki alt yükselti orman ve çalılıklarında yangın sonrası hızlı ekolojik değerlendirme ile restorasyon önerilerinin geliştirilmesi: Datça-Bozburun Özel Çevre Koruma Bölgesi örneği. *Türkiye Ormanlık Dergisi*, 23(3), 163-177.
- Visner, M., Shirowzhan, S., & Pettit, C. (2021). Spatial analysis, interactive visualisation and GIS-based dashboard for monitoring spatio-temporal changes of hotspots of bushfires over 100 years in New South Wales, Australia. *Buildings*, 11(2), 37. doi: 10.3390/buildings11020037.
- Yakar, M. (2011). Nüfus Dağılımının Mekansal Analizi: Afyonkarahisar ili Örneği. *Uluslararası Sosyal Araştırmalar Dergisi*, 4(19), 389-406.
- Yuan, Y., Cave, M., & Zhang, C. (2018). Using Local Moran's I to identify contamination hotspots of rare earth elements in urban soils of London. *Applied Geochemistry*, 88, 167-178.
- Zahran, E. S. M. M., Shams, S., & Said, S. N., Matullah B. M. (2020). Validation of forest fire hotspot analysis in GIS using forest fire contributory factors. *Systematic Reviews in Pharmacy*, 11(12), 249-255.
- Zhang, L., Tao, Z., & Wang, G. (2022). Assessment and determination of earthquake casualty gathering area based on building damage state and spatial characteristics analysis. *International Journal of Disaster Risk Reduction*, 67, 102688. doi: 10.1016/j.ijdr.2021.102688.
- Zúñiga-Vásquez, J. M., Cisneros-González, D., Pompa-García, M., Rodríguez-Trejo, D. A., & Pérez-Verdín, G. (2017). Modelación espacial de incendios forestales en México: Una integración de dos bases de datos. *Bosque*, 38(3), 563-574.

İHA Tabanlı 3 Boyutlu Verilere Farklı Perspektiflerde Bakış: İTÜ Ayazağa Kampüsü

Different Perspectives on UAV-Based 3D Data: ITU Ayazağa Campus

Semih Sami Akay^{1*} 

¹Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, İstanbul/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Semih Sami Akay
sami.akay@std.yildiz.edu.tr

doi: 10.48123/rsgis.1195012

Yayın süreci

Geliş tarihi: 26.10.2022

Kabul tarihi: 13.12.2022

Basım tarihi: 28.03.2023

Özet

İnsansız Hava Araçları (İHA), diğer veri üretim yöntemleri ile karşılaştırıldığında son yıllarda maliyet, veri türü ve çözünürlüğü açısından avantajlar sağlamaktadır. Bu kapsamda, İHA verileri klasik ölçme veya haritalama amaçları dışında farklı sektörlerde, araştırmalarda ve platformlarda kullanılmaktadır. İHA verileri, fiziksel temas sağlanmadan sanal ve çevrimiçi platformlar gibi farklı ve yeni alanlarda katılımcılar ile yeryüzü arasında etkileşim sağlamaktadır. Üç boyutlu (3B) veriler, internet sitelerine, oyun motorlarına, animasyon uygulamalarına, masaüstü ve taşınabilir cihazlarda çeşitli uygulamalara entegre edilerek gerçek yeryüzü ile kullanıcılara farklı deneyimler sunabilmektedir. 3B veri paylaşım platformları, İHA tabanlı verilere doğrudan sahip olmadan her kullanıcıya gerçeğe yakın veri üzerinde ölçüm yapma, gezerek bilgi alma, 3B deneyim yaşama, çevrimiçi sosyalleşme ve görüşme kapsamlarında olanaklar sunmakta, alana ulaşım, erişim ve maddiyat konularında her kullanıcıyı ortak paydada buluşturmaktadır. Çalışmanın amacı, İstanbul Teknik Üniversitesi Ayazağa Kampüsü yüksek çözünürlüklü nokta bulutu ve 3B model üretilmesi ile bu verilerin sanal ve çevrimiçi platformlarda farklı perspektiflerde kullanımının gösterilmesidir. Kampüs verileri Metaverse (sanal gerçeklik (VR), artırılmış gerçeklik (AR)), çevrimiçi (bilgi ve gezinme platformu ve çevrimdışı (uçuş simülasyonu, katı model üretimi) gibi farklı uygulamalarda kullanılmak üzere farklı platformlara entegre edilmiştir. Kullanıcılar kampüse fiziksel temas olmadan gezebilmekte, bilgi alabilmekte, etkinlikler düzenleyebilmekte ve deneyim kazanabilmektedir.

Anahtar kelimeler: İHA, Fotogrametri, Metaverse, Nokta bulutu, 3 Boyutlu model

Abstract

Unmanned Aerial Vehicles (UAVs) offer several advantages about cost, data type and resolution compared to other surveying methods. UAV-based data are used in research, and platform apart from classical surveying and mapping. UAV-based data has been used for various fields such as online and virtual environments to create interaction between participants and earth surface without physical contact. 3D data can be integrated into websites, games, animations, and various applications to provide experience for users about the real-world on desktop or mobile devices. 3D data platforms provide to measure, get information, live a 3D experience, socialize and meet, and it brings together users on a common ground in terms of transportation, access and materiality. The high-accuracy of point cloud and 3D model of Istanbul Technical University Ayazağa Campus with UAV-based were produced, and to show these data at different perspectives in the virtual and online environment. Data of campus were used in different application, which are Metaverse (virtual reality (VR), augmented reality (AR)), online (information, navigation), and offline (flight simulation, solid model). Users get information, experiences and tour around without physical contact.

Keywords: UAV, Photogrammetry, Metaverse, Point cloud, 3-Dimensional model

1. Giriş

Günümüzde, İHA'lar ile fotogrametrik ölçüm metodu doğrultusunda üretilen üç boyutlu model, nokta bulutu, sayısal yüzey modelleri ve ortomozaik veriler ile geniş çerçevede farklı çalışma alanları olduğu görülmektedir. İHA'lara entegre kamera sistemleri ile otomatik veya yarı otomatik olarak gerçekleştirilen uçuşlar ile elde edilen veriler, yüzeye ait yüksek görsel detaya sahip olması ile yersel ölçüm metodlarına göre birçok avantaja sahiptir. Bununla birlikte, İHA'lar, yeryüzündeki objelerin gerçeğe yakın şekilde 3B modellerinin üretilmesi açısından kolaylık sağlamaktadır. İnsan veya araç erişiminin zor veya tehlikeli olduğu çalışma alanlarında İHA'lar sahip oldukları kameralar ve LiDAR sistemleri ile elde ettikleri fotoğraf ve nokta bulutu verileri doğrultusunda yeryüzüne ait detaylı bilginin çıkarımına ve ölçüm yapılabilmesine olanak sağlayabilmektedir (Akay vd., 2022; Turner vd., 2016; Makineci, 2016). Farklı sensörlerin İHA'lara entegrasyonu ile yeryüzüne ait detaylı bilgi ve yüksek çözünürlüklü veri sağlama açısından İHA tabanlı yöntemler avantaj sağlamaktadır. Bunun yanı sıra İHA tabanlı elde edilmiş veriler yersel fotogrametri veya uzaktan algılama metodları ile elde edilen benzer özelliklere sahip veriler ile karşılaştırıldığında ise İHA tabanlı veri üretim süreçlerinin zaman ve maddi avantajlar sağladığı görülmektedir. Ayrıca İHA tabanlı veri temini sonucunda tek bir zamanda gerçekleştirilen ölçme işlemi ile farklı 2B ve 3B veri türlerinin üretimi sağlanabilmektedir. Harita üretim işlemleri kapsamında uzaktan algılama platformları ile İHA'lar karşılaştırıldığında düşük bütçe ile yüksek zamansal çözünürlüğe sahip veri temini sağlandığı görülmektedir. Ayrıca İHA'lar, bölgesel çalışmalarda da geleneksel metodlar ve uzaktan algılama platformlarına göre hava koşullarından (bulutluluk, yağmur vb.) daha az etkilenecek kısa zamanda düşük bütçe ve iş yükü ile yüksek çözünürlüklü veri temini gerçekleştirebilmektedir. Bununla birlikte, gelişmiş konumlandırma sistemleri olan Real Time Kinematic-Gerçek Zamanlı Kinematik (RTK) modüllerinin İHA'lara entegre edilmesi veya yersel Global Positioning System-Küresel Konumlama Sistemi (GPS) ölçümleri ile entegreli olacak şekilde gerçekleştirilen İHA uçuşları ile yüksek doğruluklu ve yüksek mekansal çözünürlüğe sahip 3B modeller, sayısal yüzey modelleri (SYM) ve ortomozaik verilerin üretimi gerçekleştirilmektedir (Akay vd., 2017; Akay vd., 2022; Turner vd., 2016).

İHA'ların fotogrametri metodu ile kullanılması İHA fotogrametrisi terimini ortaya çıkarmaktadır. Bu kapsamda, yüksek çözünürlük nokta bulutu, 3B model, sayısal yükseklik modeli ve ortomozaik verilerin üretilmesi için İHA fotogrametri metodunda sıklıkça kullanılan Structure from Motion (SfM) yöntemi ile düzenli olmayan hava fotoğraflarındaki ortak noktalar eşleştirilerek veri üretim işlemleri gerçekleştirilmektedir (Snively vd., 2007; Özkaya vd., 2021). Bu teknik ile üretilen veriler ile uzunluk, alan, hacim ölçümlerinin yanı sıra yerleşim ve doğal alanlarda fiziki olarak erişimi olmayan bölgelerin görsel olarak sunumları da gerçekleştirilebilmektedir (Javernic vd., 2014; Jaud vd., 2016, Seki vd., 2017; Şasi ve Yakar, 2018). İHA'lar ile elde edilen veriler sonucunda doğa kaynaklı meydana gelen afetlerin, yapıların, morfolojik değişimlerin, kütle hareketlerinin, şehirlerin ve tarım arazilerinin izlenmesi, üç boyutlu modelleme, dijital ikiz uygulamaları, arkeoloji alanları, restorasyon ve mimarlık gibi birçok farklı çalışmalar gerçekleştirilmektedir. Özellikle İHA fotogrametrisi ile ortomozaik, sayısal yükseklik modeli, nokta bulutu verilerinin üretimi sonucunda elde edilen verilerin çeşitliliği aynı çalışmada birçok alan, uzunluk ve hacim ölçümleri ile farklı analizlerin de gerçekleştirilmesine olanak sunmaktadır (Salamí vd., 2014; Yakar vd., 2016; Ulvi, 2018; Ulvi vd., 2020; Ağca vd., 2020; Senkal vd., 2021; Akay vd., 2022; Özcan ve Özcan, 2021; Özcan vd., 2022; Levine ve Spencer, 2022; Maraş ve Nasery, 2023).

3B veriler, sanal gerçeklik (virtual reality - VR) ve artırılmış gerçeklik (augmented reality - AR) uygulamaları ile entegre edilerek kullanıcılar ile verilerin etkileşimi sağlanmaktadır. Bu deneyim, sanal ortamda bir bölgede gezilebilir olanağı ve başka bir yerde olma hissini verebilmektedir (Chang vd., 2015; Gerloni vd., 2018; Scaravetti ve Doroszewski, 2019). Sanal ortam deneyimlerinin sonucunda fiziksel temas kurmadan, gerçek ortam hakkında kavranan hisler yeni bir yaklaşım olan Metaverse kavramı kapsamında değerlendirilmektedir. Metaverse kavramı, fiziksel gerçekliğin dijital gerçeklik ile entegre edilerek kullanıcıların gerçek dünya dışında bir araya gelerek etkileşimde bulunmasını sağlayan dijital ortam olarak sunulmaktadır (Mystakidis, 2022). Yazılım tarafından üretilen verilerin, donanım ve çevrimiçi arayüzler ile gerçekçi bir sanal ortamda kullanıcılar ile etkileşime girmesi sağlanmaktadır. Üretilen veriler, Metaverse ile kullanıcılara akademi, eğitim, endüstri ve oyunlar gibi çeşitli alanlarda farklı deneyimler sunabilmektedir (Chang vd., 2015; Halik ve Smaczyński, 2018; Gerloni vd., 2018; Scaravetti ve Doroszewski, 2019; Kalacska vd., 2021; Narin, 2021; Lee vd., 2021; Mystakidis, 2022).

İHA ile gerçekleştirilen uçuşlar sonrasında 3B model ve nokta bulutu verileri özelinde çalışmalar incelendiğinde doğal alanlarda, yapılarda, kültürel miras alanlarında modelleme, belgeleme, restorasyon ve röleve çalışmaları, 3B baskı, doğal afet simülasyonları, animasyonlar, oyunlar, sınıflandırma işlemleri ile bina ve yol çıkarımları, konumsal ve yükseklik ölçümleri gibi çalışmalarda kullanıldığı görülmektedir (Ulvi ve Toprak, 2016; Ulvi vd., 2020; Hamal vd., 2020; Yang vd., 2021; Gallo vd., 2021, Berrett vd., 2021, Erdoğan vd., 2021; Rezaldi vd., 2021; Bayramoğlu ve Uzar, 2023). Yüksek doğrulukla elde edilen bu veriler sanal turlar gibi gezme uygulamalarında da kullanıldığı görülmektedir (Sefercik vd., 2021). İHA ile üretilen veriler, yersel lazer tarayıcı verileri ile entegre edilerek yüksek doğruluklu 3B modeller üretilmektedir. 3B modeller oyun motorlarına entegre edilerek farklı uygulamalar için farklı detay seviyelerinde kullanılabilir (Şenol vd., 2021; Andaru vd., 2019).

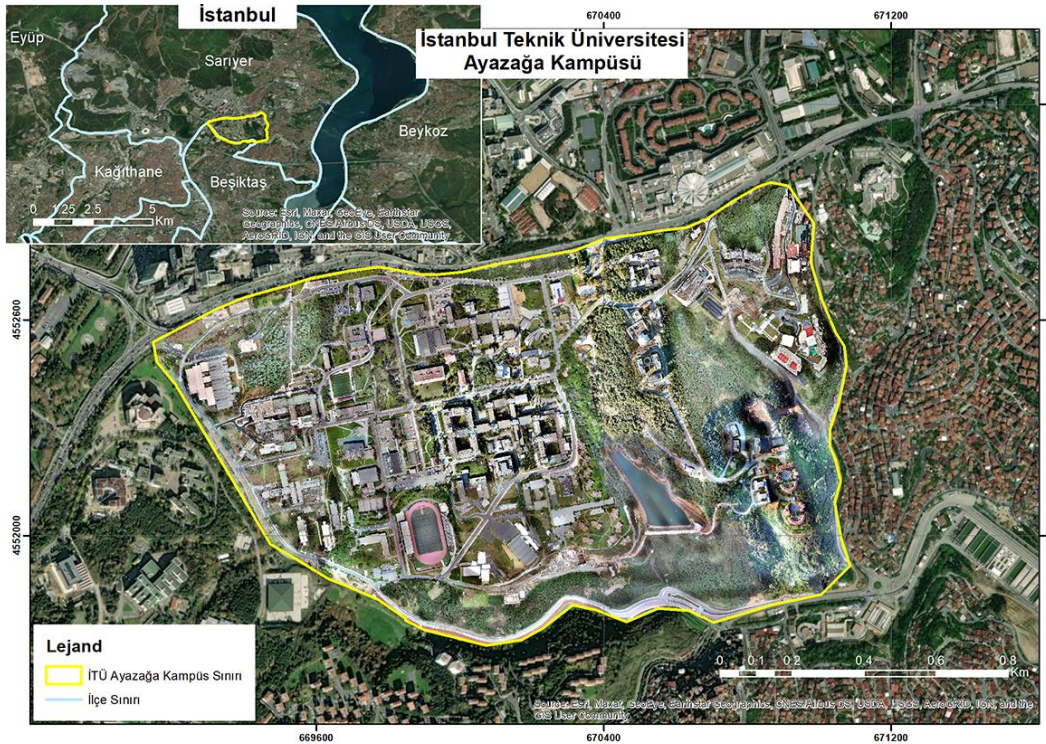
Oyun motorlarına entegre edilen İHA tabanlı 3B arkeolojik ve kentsel yapılar, binalar, yollar ve alanlar kullanılarak yeryüzünde farklı oyun türleri kapsamında ve verilerin görselleştirilmesi ile kullanıcılara gerçeğe yakın deneyimler yaşatılabilmektedir (Qin vd., 2012; Teke, 2016; Laksono vd., 2019; Andaru vd., 2020; Weißmann vd., 2022). Ayrıca 3B modeller animasyon uygulamalarına entegre edilerek yazılımlarda gerçekleştirilen tasarım işlemlerinin kolaylaştırılmasını sağladığı, daha hızlı ve gerçeğe en yakın bir şekilde animasyonların üretilmesini sağlamakta kullanıldığı görülmektedir (Rocca, 2021; Rezaldi vd., 2021).

Günümüzde sürekli olarak gelişen bir teknoloji olan İHA'ların harita ve fotogrametri alanları kapsamında kullanılmasıyla 2017 yılında veri alımı ve üretimi süreçlerine başlanan ve farklı uygulamalar kapsamında gerçekleştirilen bu çalışmada, ülkemizde ilk kez İHA kullanılarak üretilen 3B kampüs modeli olarak İstanbul Teknik Üniversitesi (İTÜ) Ayazağa Kampüsü'ne ait 3B modeli, ortomozaik, sayısal yükseklik modeli ve nokta bulutu verilerinin yüksek doğrulukla ve çözünürlükle üretilmesi ile sanal ortamda sunulması sağlanmıştır. Bu çalışmada gerçekleştirilen uygulamalar, akademik, eğitsel veya oyun dışında kullanılan verilerin üretilmesi ile kullanıcıya üniversite hakkında kapsamlı bilgi sunmayı amaçlamaktadır. Ayrıca Metaverse kavramı kapsamındaki platformlarda kampüse ait 3B modelin sunulması ile kullanıcıların üniversite ile etkileşimi sağlanmaktadır. Bu kapsamda, üniversite kampüsü hakkında detaylı olarak üç boyutlu konumsal ve öznitelik bilgileri, kullanıcıların birbirleri ile etkileşimleri kapsamında üniversite kampüsünün ilgili alanlarında etkinlik organizasyonları ve sanal olarak erişimi sağlanmaktadır. Verilerin çevrimiçi ve sanal ortamlarda sunulmasının yanı sıra İHA tabanlı verilerden kampüs binalarının katı modellerinin üretilebileceği görülmektedir. Çalışma, kampüs boyutu, İHA uçuş sayısı, üretilen verilerin çeşitliliği ve verilerin farklı uygulamalarda kullanılması açısından İHA tabanlı verilerin kullanım alanlarını detaylı olarak göstermektedir.

2. Çalışma Alanı ve Veri Seti

2.1 Çalışma Alanı

Çalışma, İstanbul il sınırları içerisinde İTÜ'nün beş farklı kampüsünden biri olan ve Maslak'ta bulunan yaklaşık 168 ha'lık alansal değere sahip olan ve UI GreenMetric sıralamasında dünyanın en yeşil 57. kampüsü olan İTÜ'nün en büyük yerleşkesi İTÜ Ayazağa Kampüsü'nde gerçekleştirilmiştir (İTÜ, 2022; İTÜ Yeşil Kampüs, 2022). Kampüs içerisinde yapay göl, stadyum, yüzme kompleksi, sekiz fakülteye ait yedi bina ile idari, girişimcilik ve inovasyon binaları olmak üzere yaklaşık elli adet bina bulunmaktadır (İTÜ, 2022). Bu kapsamda kampüs incelendiğinde, kampüsün kentsel alanlar ile benzer şekilde olduğu, doğal ve yapay yüzey/objelerin de kampüs sınırları içerisinde bulunduğu görülmektedir. Şekil 1'de İTÜ Ayazağa Kampüsü'nün konumu ve kampüse ait ortomozaik verisi ile kampüs sınırı gösterilmiştir.



Şekil 1. İTÜ Ayazağa Kampüsü konumunun gösterimi

2.2 Veri Seti

Çalışma kapsamında, hava fotoğraflarının temini ile nokta bulutu, 3B model ve ortomozaik veri üretmek amacıyla 12MP çözünürlüğe sahip entegre kamerası bulunan ve yaklaşık 23 dakikalık uçuş süresine sahip DJI Phantom 3 Pro model İHA ile uçuşlar gerçekleştirilmiştir. İHA yaklaşık olarak 1.5 kg ağırlığında olmakla birlikte entegre GPS konumlandırma sistemleri ile fotogrametrik uçuş planlarının hazırlanması ile uçuşların gerçekleştirilmesine imkan sağlamaktadır. İHA ile gerçekleştirilen fotogrametrik uçuşlar sırasında elde edilecek hava fotoğraflarının örtüşme oranları uçuş planlama yazılımlarında belirlenmektedir. İHA uçuş planlamaları, verinin yer örneklem aralığına bağlı olarak uçuş yüksekliği, kamera odak uzaklığı, örtüşme oranları ve uçuş sürelerine göre planlanarak gerçekleştirilir. Bu parametreler, 3B modelleme ve haritalama işlemleri kapsamında yüksek çözünürlüklü veri üretmek veya acil durumlarda izleme ve yönetim kapsamında hızlı veri temini amacı gibi farklı amaçlara göre değiştirilebilmektedir (Nex ve Remondino, 2014). Bu çalışma kapsamında hava fotoğrafları arasındaki ortak bağlantı noktalarını eşleştirmek için yan ve ön örtüşme oranları % 90 olacak şekilde veri temini gerçekleştirilmiştir. Çalışmada, İHA ile gerçekleştirilen fotogrametrik uçuşlar, yerleşke yönetiminden alınan izinler ve yasal sınırlar kapsamında yerden 100 m yükseklikte gerçekleştirilmiştir. Ayrıca, kampüste bulunan yüksek binalar, baz istasyonları, elektrik direkleri, uydu antenleri vb. çevresel faktörler dikkate alınarak en uygun İHA uçuş planları hazırlanarak uçuşlar gerçekleştirilmiştir. Bu kapsamda, tüm kampüse ait verilerin elde edilmesi amacıyla 20 adet İHA uçuş planı ile uçuşlar gerçekleştirilmiştir. 2017 ve 2018 yılının ilkbahar ve yaz aylarında hava koşulları dikkate alınarak İHA uçuşları gerçekleştirilmiştir. İHA uçuşları sonucunda kampüse ait 8172 hava fotoğrafı elde edilmiştir.

Çalışma sırasında, yüksek doğrulukla veri üretimi amacıyla kampüs içerisinde yer kontrol noktaları (YKN) belirlenerek uçuşlarla eş zamanlı olarak RTK metodu kullanılarak yersel GPS ölçümleri ile YKN'lerin koordinat ölçümleri gerçekleştirilmiştir. İHA'lar ile elde edilen hava fotoğraflarının işlenmesi öncesinde YKN'ler hava fotoğraflarında işaretlenerek sisteme entegre edilmiştir. Hava fotoğraflarının eşleştirilmesi ve bağlama noktalarının belirlenmesi ile az yoğun nokta bulutu üretimi gerçekleştirilerek sırasıyla yoğun nokta bulutu, 3B model ve ortomozaik verilerin üretimi tamamlanmıştır.

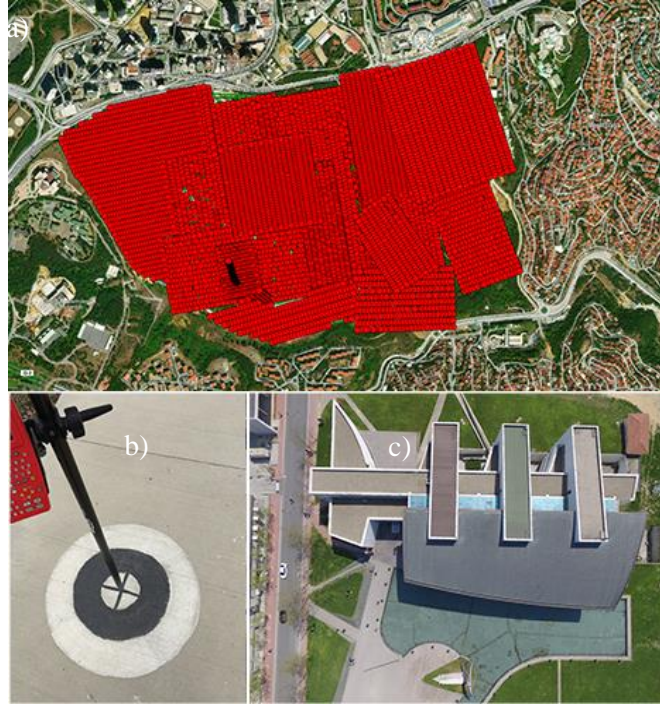
Son yıllarda yüksek çözünürlüklü veri setleri üzerinde büyük ölçekte çalışmayı düşük maliyetle mümkün kılan ve kullanıcılar açısından avantajlı fotogrametrik ölçüm metodu sağlayan Structure-from-Motion (SfM) tekniği kullanılmaktadır. SfM tekniği, gözdeki retina tabakasında oluşturulan iki boyutlu hareketli görüntülerden çevrenin üç boyutlu ortamının insanlar tarafından algılanmasına karşılık gelen biyolojik görüntü algılamasını simüle etmektedir. Bu teknik, görüntülerdeki nesnelerin kamera parametrelerini, konumlarını ve üç boyutlu geometrilerini otomatik olarak ayarlayarak üç boyutlu modellerin oluşturulmasını sağlayan görüntü tabanlı bir modelleme tekniğidir (Snaveily vd., 2007). SfM, fotogrametrik ölçüm işlemlerine dayalı olarak belirli bir örtüşme oranı ile farklı konumlarda çekilmiş bir dizi fotoğraftaki nesnelerin eşleştirilmesine dayalı olarak nesnelerin üç boyutlu olarak modellemesini sağlamaktadır. Görüntüler arasındaki ilişkileri bulabilmek için kenarlar, köşeler vb. özellikler örtüşmeli olarak çekilmiş fotoğraflarda belirlenmektedir. Son yıllarda ticari yazılımlar, SfM tekniği ile İHA'lardan elde edilen hava fotoğraflarının işlenmesini sağlayarak verilerin üretilmesini sağlamaktadır (Snaveily vd., 2007; Colomina ve Molina, 2012; Lucieer vd., 2014; Shervais, 2016).

İHA ile üç boyutlu yüzeylerin üretimi kapsamında; SfM fotogrametrik ölçüm adımlarından sırasıyla örtüşen görüntülerin eşleştirilmesi, yoğun nokta bulutlarının oluşturulması, yoğun nokta bulutu üzerinden üç boyutlu ağ modeli, üç boyutlu model ve ortomozaik üretim gerçekleştirilmektedir (Javernick vd., 2014; Woodget vd., 2015; Jaud vd., 2016). Bu kapsamda öncelikle ışın demeti dengelemesi ve kamera hizalaması yapılmaktadır. Örtüşmeli olarak temin edilen fotoğraf serilerinin düzeltilmesi için harici kamera parametreleri ve kamera kalibrasyon parametreleri hesaplanarak, seri olarak çekilen fotoğrafların örtüşen bölgelerinde ortak bağlantı noktaları tespit edilir ve eşleştirilmesi sağlanır. Eşleştirilmiş görüntüler üzerinden yoğun nokta bulutlarının üretilmesi için, yazılımdaki stereo fotogrametrik denklemler ile her bir bağlantı noktasının konumunun hesaplanması gerçekleştirilir. Farklı 3B modelleme çalışmalarında az yoğun nokta bulutu veya yoğun nokta bulutu verileri ayrı olarak kullanılmaktadır. Ortomozaik üretiminde, distorsiyonların kaldırılması ve yüksek hassasiyet ile verinin üretilmesi için yoğun nokta bulutu verisine ihtiyaç duymaktadır. Yoğun nokta bulutundaki noktalar ile üç boyutlu poligon ağ modeli oluşturulması ile ortomozaik verilerinin üretimi gerçekleştirilmektedir. Sayısal yüzey modeli ise düzensiz poligon ağ modelinin düzenli bir ızgara üzerinde interpolasyonu ile oluşturulmaktadır (Snaveily vd., 2007; Javernick vd., 2014; Nex ve Remondino, 2014).

SfM tekniğinden üretilen veriler konumlandırılmaları ve doğrulukları, İHA'lar üzerinde entegre olarak bulunan GPS sistemleri ile gerçekleştirilmektedir. İHA uçuşları kapsamında havada fotoğraf çekimi sırasında fotoğrafların konumları, bu sistemler ile belirlenmektedir. Bu nedenle fotoğrafların konumsal doğruluğu bu sistemlerin konumsal hassasiyetlerine göre yaklaşık olarak hesaplanmakta ve üretilen verideki nesnelerin konumsal doğruluğu, gerçek konumlarına göre yaklaşık konumlar olarak hesaplanmaktadır. Konum doğruluğunun yüksek doğrulukla hesaplanabilmesi için YKN'ler veri üretim işlemleri sırasında yazılımlara entegre edilmektedir.

Çalışmada, yüksek doğrulukla veri üretebilmek amacıyla kampüs alanına homojen olarak dağıtımı gerçekleştirilen 35 adet YKN ile veri üretimi gerçekleştirilmiştir. YKN'lerin koordinat ölçümleri RTK metodu ile yersel GPS ölçümleri gerçekleştirilmiştir. Ölçülen YKN noktalarının konumsal doğruluklarının 1.7 cm ile 3.3 cm arasında olduğu görülmektedir. YKN'lerin koordinat sistemi UTM projeksiyonu 35. Kuzey Dilimi, Datumu WGS 84'tür. Ölçümü gerçekleştirilen YKN'ler çalışmada elde edilen hava fotoğraflarında işaretlenerek sırasıyla nokta bulutu, 3B model ve ortomozaik verilerin üretim aşamaları gerçekleştirilmiştir.

İHA ile veri üretim süreci, kullanılan donanım ve yazılımlara göre değişiklik göstermektedir. İHA'lar ile temin edilen görüntü sayısı, veri üretim parametreleri ve donanım özellikleri veri üretim süresini etkilemektedir. Dolayısıyla İHA'lar ile temin edilen görüntü sayısı arttıkça donanımın sahip olması gereken bellek ve ram miktarının da artırılması önerilmektedir (Shervais, 2016; Akay vd., 2017).




Şekil 2. a) İHA ile temin edilen hava fotoğraflarının gösterimi, b) yer kontrol noktasının gösterimi, c) İHA ile temin edilen hava fotoğrafının gösterimi

Çalışma kapsamında, İTÜ Avrasya Yer Bilimleri bünyesinde bulunan Earth3Bee Lab. – 3 Boyutlu Yer Modelleme Laboratuvarı'nda veri işleme ve üretimi kapsamında kullanılan yazılım ve donanımlar kullanılmıştır. Laboratuvar bünyesindeki donanım, İHA'dan temin edilen tüm hava fotoğraflarının aynı anda işlenmesine olanak sağlayacak durumda olduğundan dolayı tüm görüntülerin tamamı aynı anda sisteme entegre edilerek veri üretim işlemleri gerçekleştirilmiştir. İHA uçuşları sonucunda elde edilen görüntülerin konumları Şekil 2'de gösterilmektedir.


Gerçekleştirilen İHA uçuşları sonucunda, İTÜ Ayazağa Kampüsü'ne ait 8172 adet hava fotoğrafı sisteme entegre edilmiş ve veri üretim işlemi gerçekleştirilmiştir. Veri üretimi için kullanılan mevcut sistem 128 GB RAM ve 1.276 TB depolama alanına sahip olmakla birlikte veri üretim süresi yaklaşık 72 saat sürmüştür. Veri üretim süreci sonucunda İTÜ Ayazağa Kampüsü'ne ait yoğun nokta bulutu, 3B model ve ortomozaik veriler üretilmiştir.

Kampüse ait üretilen nokta bulutu verisi 270.390.128 nokta içermekle birlikte kampüs kapsamında 1m² alan içerisinde 160 nokta olarak görülmektedir. İTÜ Ayazağa Kampüsü'ne ait yoğun nokta bulutu verisi ile spor alanını gösteren kesit Şekil 3'te görülmektedir.

Kampüse ait nokta bulutu verisi kullanılarak İTÜ Ayazağa Kampüsü'ne ait 3B modelinin üretimi gerçekleştirilmiştir. Üretilen 3B kampüs modeline ait kampüsün tamamını ve detaylı alanlarını Şekil 4'te gösterilmektedir.




Şekil 3. İTÜ Ayazağa kampüsü nokta bulutu verisi; a) İTÜ Ayazağa kampüsü, b) spor alanı



Şekil 4. İTÜ Ayazağa kampüsü üç boyutlu modeli; a) kampüsün üç boyutlu genel görünümü, b) fakültelerin ve İTÜ stadyumunun görünümü, c) lojmanların görünümü

İHA uçuşları sonucunda elde edilen hava fotoğrafları sonucunda ile üretilen ortomozaik verinin yer örnekleme aralığı (YÖA) 5 cm, karesel ortalama hata ise 0.211 pikseldir (Şekil 5). Nokta bulutu, üç boyutlu model ve ortomozaik verileri farklı büyüklükteki boyutları ile donanımların depolama alanlarında yer kaplamaktadır. Kampüse ait üretilmiş nokta bulutu, üç boyutlu model ve ortomozaik verileri sırasıyla 4.35 gigabyte, 2.90 gigabyte ve 1.93 gigabyte ile depolama alanında yer kaplamaktadır.



Şekil 5. İTÜ Ayazağa kampüsü ortomozaik verisi

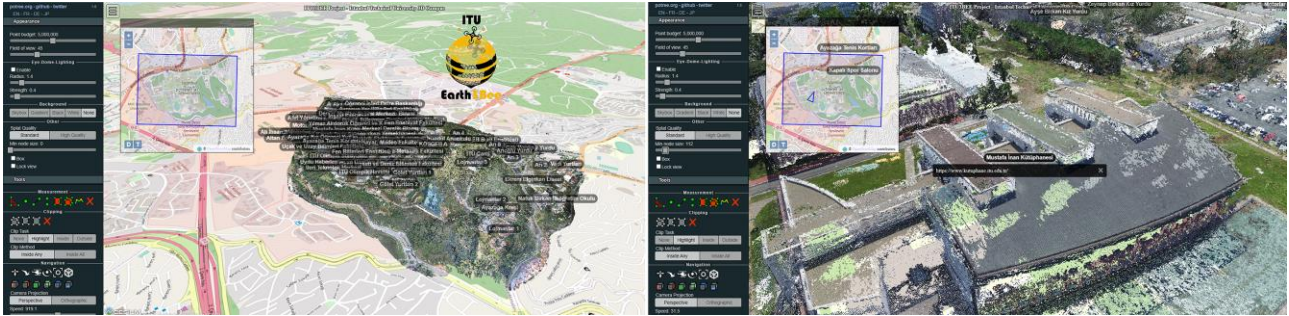
Çalışma kapsamında üretilen veriler farklı platformlar aracılığı ile kullanıcılara sunulmuştur. Öncelikle 3B kampüs modeli ile oyun motorları kullanılarak İTÜ öğrencilerinin erişimine açılacak bir oyun projesi tasarlanmış, fakat oyun motorlarına veri entegrasyonu sırasında 3B kampüs modelinin boyutunun ve model içerisindeki üçgen model sayısının yüksek olmasından dolayı gerçekleştirilememiştir. Sanal gerçeklik ve çevrimiçi platformlarda 3B kampüs modelinin sunulması sırasında oyun motorları ile benzer süreçler yaşandığı görülmektedir. 3B kampüs modelinin, oyun motorlarına ve metaverse platformlarına entegrasyonu sırasında 3B model düzenlenerek boyutu ve üçgen model poligonu sayısının düşürülmesi ile çözünürlüğünün düştüğü görülmektedir. Dolayısıyla oyun motorlarına veri entegrasyonu sırasında 3B modellerin bir kısmının ya da sadece objelerin entegrasyonun gerçekleştirilmesi önerilmektedir. Çalışmada, kampüsün tamamını içeren 3B nokta bulutu çevrimiçi platformda sunulmuştur. İTÜ Ayazağa Kampüsü 3B model verisinin yüksek boyutu ve yüksek sayıdaki üçgen modeli poligonu nedeniyle metaverse, çevrimiçi ve çevrimdışı platformlar kapsamında bölgelere ayrılarak platformlara entegre edilmiştir. 3B kampüs modelinin, 3B yazıcı ile 3B katı modelinin çıktısı alınırken yazıcıların baskı özellikleri dikkate alınarak kampüs içerisinde bulunan kütüphane binasının çıktısı alınmıştır.

3. Üç Boyutlu Kampüs Modeli Uygulamaları

İHA'lar ile üretilen yeryüzüne ait veriler mimari, inşaat, tarım, orman, haritalama gibi birçok farklı amaç ve sektörde kullanılmaktadır. Veriler üzerinde noktasal konum ölçümlerinin yanı sıra hem yatay hem de düşey ölçümler gerçekleştirilebilmektedir. Dolayısıyla İTÜ Ayazağa Kampüsü'ne ait üretilen veriler ile kampüs üzerinde gerçekleştirilecek çalışmalar için altlık bir veri seti üretimi gerçekleştirilmiştir. Üniversitelerde inşaat ölçümleri dışında gerçekleştirilecek konserler, yarışmalar vb. etkinlikler için uygun alanların ve bu alanların kapasitelerin belirlenmesi amacıyla uzunluk, alan, hacim ölçümleri gerçekleştirilebilmektedir. Bununla birlikte günümüzde pandemi sürecinde olduğu gibi kapanma durumları veya ulaşımdan kaynaklı yaşayacağımız fiziki erişimin olmadığı zamanlarda ise çevrimiçi ve sanal ortam platformları aracılığı ile kampüs üzerinde ölçüm, tanıtım veya gezi gibi çalışmaların ve aktivitelerin gerçekleştirilmesi de sağlanabilmektedir. Ayrıca, kampüse ait üretilmiş 3B model ve nokta bulutu verileri, üniversiteye ait öğrenci kulüplerinin düzenlediği oyun, etkinlik vb. amaçlarla kullanılabilir. Kampüse doğrudan erişim olmadan kampüs hakkında kampüs içi ulaşım, bölüm binaları, bina konumu, detaylı özellikleri gibi bilgilere erişilebilmektedir.


3.1 3B Model ve Nokta Bulutu Verilerinin Çevrimiçi ve Çevrimdışı Platformlara Entegrasyonu

Gelişen teknoloji farklı özelliklere sahip veri türlerinin, farklı platformlarda kullanılmasına imkan sağlayabilmektedir. Bu kapsamda kullanılan yazılımların özelliklerine göre nokta bulutu ve 3B modeller için farklı veri türleri (.fbx, .obj, .mtl, .stl, .las, .laz, .dae vb.) kullanılmaktadır. Veri türleri içerdikleri doku, üçgen modeli poligonlarına ve model yapılarına (çizgi, poligon, katı model vb.) göre değişiklikler göstermektedir. 3B veriler, paylaşım platformlarının veri gösterim ve değerlendirme özelliklerine göre düzenlenebilmekte ve farklı veri formatlarına dönüştürülmektedir. Farklı formatlardaki veriler, yüzey dokusu bulundurma, katı model olarak düzenlenebilme ve baskı formatlarına uygunluk gibi değişiklikler göstermektedir. Uygun veri platformlarında paylaşımlar için 3B modellerin veri boyutlarında veya çözünürlüklerinde arttırma veya düşürme işlemleri gerçekleştirilmektedir. İHA ile veri üretim sürecinde verilerin kullanılacağı platformlara göre veri türlerinin seçimi ve üretimi gerçekleştirilebilmektedir. Özellikle İHA ile üretilen verilerin boyutları ve özellikleri karşılaştırıldığında üç boyutlu modellerin, nokta bulutlarına göre daha yüksek boyuta, mevcut üçgen modeli poligonlarından ve dokularından dolayı kompleks yapıya sahip olduğu görülmektedir. Nokta bulutu verisi çevrimiçi platformlarda sunularak 3B veri üzerinde uzunluk, alan ve hacim ölçümleri gerçekleştirilmektedir. 3B veri üzerinde kesit alınabilmekte ve kesit içerisinde kalan noktaların yatay ve düşey konumları ile hesaplamalar gerçekleştirilmektedir. Çok zamanlı üretilecek 3B veriler ile çalışılan alanlarında değişim analizleri gerçekleştirilebilmektedir. Ayrıca üç boyutlu modellerin sunulduğu platformlardaki etiketleme özellikleri nokta bulutu platformunda kullanılarak kampüs hakkında detaylı açıklamalar yapılarak öznelik bilgilerinin gösterimi gerçekleştirilmektedir. Potree platformu, nokta bulutu verilerinin gerçek konumlarına ve veri üzerindeki objelerin özneliklerinin etiketlenmesi ile kullanıcılara çevrimiçi olarak sunulmasını sağlamaktadır (Potree, 2022). Bu kapsamda, İTÜ Ayazağa Kampüsü, çevrimiçi olarak açık kaynak 3B nokta bulutu görselleştirme platformu olan Potree platformuna entegre edilerek kullanıcıların erişimine açılmıştır (ITUBEE, 2022). 3B kampüs modeli çevrimiçi olarak herhangi bir mobil cihaz ile gezilebilmekte, detaylı bilgiler alınarak veri üzerinde ölçümler gerçekleştirilebilmektedir (Şekil 6).



Şekil 6. Objelerin öznelik bilgilerinin 3B kampüs üzerinde görünümü (ITUBEE, 2022)

Nokta bulutu verileri üzerinde alınan kesitler ile yüzeydeki yükseklik değişimlerini ve objelerden kaynaklı farklılıklar görülebilmekle birlikte objelerin yüksekliklerinin ölçümleri de gerçekleştirilebilmektedir (Şekil 7). Yol veya bina gibi objelerin yükseklikleri veya uzunlukları için nokta bulutu verisi üzerinde ölçümler gerçekleştirilmektedir. Yüzeyde çizilen bir kesit ile kesit doğrultusunda yataydaki uzunluk ve yükseklik değişimleri görülebilmektedir. Bir binanın yüksekliğinin belirlenebilmesi için benzer şekilde zeminden başlayan bir kesit, binanın yüksekliği boyunca çizilerek bina yükseklikleri ölçülebilmektedir. Ayrıca nokta bulutu verisi üzerinde yükseklik değerlerine göre yüzeyin sınıflandırılması ve gösterimi gerçekleştirilebilmektedir. Şekil 7'de çevrimiçi platformda nokta bulutu verisinin yükseklik değerlerine göre gösterimi ile yüzey ve binaların yükseklikleri, bölgesel yükseklik değişimleri gibi bilgiler 3B olarak görülebilmektedir.



Şekil 7. Nokta bulutu verisinin çevrimiçi platformda sunumu; a) yüksekliklerin 3B olarak sınıflandırılarak gösterimi, b) 3B kampüs modeli üzerinde kütüphane binasının kesitinin gösterimi (ITUBEE, 2022).

Çalışma kapsamında İHA tabanlı üretilmiş 3B kampüs modeli farklı amaçlara öncülük edebilmesi amacıyla farklı platformlarda farklı amaçlarla kullanıcılara açılarak farklı deneyimler kazandırması amaçlanmıştır. Nokta bulutu verisinin kullanımına benzer şekilde 3B modellerin sunumlarını sağlayan platformlardan olan Sketchfab ve Cesium platformlarında 3B modellerin sunumu gerçekleştirilmektedir (Sketchfab, 2022; Cesium, 2022). Sketchfab ve Cesium platformları incelendiğinde, Sketchfab uygulaması kullanıcılara ücretsiz olarak belirli düzeyde bir modelin sunumuna imkan vermekle birlikte her iki platform için çalışma sırasındaki sürümlerinden dolayı düşük boyutlardaki modeller ve bölgeler çalışmada kullanılmıştır. İTÜ Ayazağa Kampüsü 3B modeli, örnek model gösterimlerinin sunulması amacıyla bölgelere ayrılarak Sketchfab ve Cesium platformuna entegre edilerek sunum gerçekleştirilmiştir.

Sketchfab platformu, düşük veri boyutundaki 3B modellerin ücretsiz, yüksek veri boyutundaki 3B modellerin ise ücretli olarak kullanıcılara çevrimiçi ve VR ortamında sunulmasını sağlayan bir platformdur (Sketchfab, 2022). Sketchfab platformu ile çevrimiçi olarak sunulan 3B kampüs modelleri üzerinde üniversiteye ait fakülte, idari, yurt, lojman, teknokent binaları ve stadyum gibi yapılar model üzerinde etiketlenerek bilgi verme amaçlı öznitelikleri gösterilmektedir. Çevrimiçi ortamda üç boyutlu kampüs modeli üzerinden gezilmesi ile üniversiteye ait detaylı bilgiler elde edilebilmektedir (Şekil 8). Üniversite tercihleri, fakülte, yurt bilgisi gibi aday öğrencilerin dikkatini çekebilecek veriler sunularak üniversitenin ilgi görmesi sağlanabilmektedir. Ayrıca öğrencilerin ilgi noktaları belirlenerek fakülte, kafe, spor vb. noktaların özniteliklerinin çeşitlendirilmesi ile detaylı bilgiler aktarılabilir.



Şekil 8. Objelerin öznitelik bilgilerinin 3B kampüs üzerinde görünümü (Sketchfab, 2022)

Cesium platformu 3B verilerin gerçek konumları ile dünya üzerinde gösterilmesini sağlayan, çeşitli uygulamalar ile entegrasyonu sağlanarak veriler üzerinde animasyon ve simülasyonların gerçekleştirilebildiği açık kaynak kodlu bir platformdur (Cesium, 2022). Çalışma kapsamında, mevcut donanım ve model özelliklerinden dolayı Cesium platformuna 3B modellerin entegrasyonu sırasında modeller düşük veri çözünürlüğü ile platforma entegre edilmiştir. Bu kapsamda, 3B kampüs modelinin tamamının platforma entegrasyonu gerçekleştirilemediği için İTÜ Ayazağa Kampüsü 3B modeli üzerinde bulunan İTÜ Mustafa İnan Kütüphanesi 3B modeli ile İTÜ Lisansüstü Eğitim Enstitüsü 3B modelleri ayrı olacak şekilde Cesium platformuna entegre edilmiştir (Şekil 9).



Şekil 9. a) Cesium platformunda, 3B modellerin gerçek konumları ile uydu görüntüsü üzerinde gösterimi, b) İTÜ Lisansüstü Eğitim Enstitüsü ve c) İTÜ Mustafa İnan Kütüphanesi (Cesium, 2022)

Çevrimdışı platformlara entegre edilen 3B modeller sabit bir donanımda çevrimiçi platformlar gibi farklı uygulamalar aracılığı ile bilgi verebilmektedir. Bunun yanı sıra ise 3B modeller özellikle eğitim kapsamında da kullanılabileceği görülmektedir. Uçuş eğitimleri kapsamında, İHA uçuş eğitimlerinin simülasyonlara entegre edilebilecek bir bölgeye veya objeye ait 3B model etrafında gerçekleştirilmesi, İHA pilotlarının uçuş kabiliyetlerinin artırılmasını sağlayabilecektir. Bu kapsamda, İHA pilotlarına ve adaylarına farklı İHA uçuşlarının İHA kumandası ile deneyimlenmesini ve pratik kazanılmasını sağlayan uçuş simülasyon platformu olan DJI Flight Simulator ile çalışma gerçekleştirilmiştir (DJI, 2022).

Üniversitede gerçekleştirilebilecek eğitimler düşünülerek, İTÜ Ayazağa Kampüsü 3B modeli DJI Flight Simulator platformuna entegre edilerek İHA kumandası ile İHA uçuşlarının kampüs üzerinde gerçekleştirilmesi sağlanmaktadır. Dolayısıyla İHA pilotları yeryüzünde bulunan ağaç, elektrik direği, bina vb. objelere dikkat ederek uçuşlarını gerçekleştirmekte ve kabiliyetlerinin artırılmasını sağlamaktadır. Şekil 10'da İHA uçuş simülasyonuna entegre edilmiş İTÜ Ayazağa Kampüsü 3B modeli üzerinde İHA kumandası ile İHA uçuşları gerçekleştirildiği görülmektedir.



Şekil 10. Kampüs 3B modelinin İHA uçuş simülasyonunda görünümü (DJI, 2022)

3.2 3B Modelin Metaverse ve Sanal Ortam Platformlarına Entegrasyonu

Günümüzde ise İHA'lar ile üretilen modellerin sanal gerçeklik ve artırılmış gerçeklik ortamlarında Metaverse kavramı doğrultusunda çeşitli ücretli ve ücretsiz platformlar aracılığı ile 3B modeller üzerinde gezilebilmekte ve ölçümler gerçekleştirilebilmektedir. Çalışmada, Metaverse kavramı doğrultusunda fiziksel gerçeklik ile dijital gerçekliğin bir arada sunulduğu platformlarda, İTÜ Ayazağa Kampüsü'ne ait 3B model kullanıcılara açılacak şekilde entegre edilmiştir. Sanal gerçeklik ya da artırılmış gerçeklik ortamlarında genellikle çizimler ile üretilen ve daha az sayıda poligona sahip 3B modellerin kullanıldığı görülmektedir. İHA'lar ile üretilen 3B modeller üçgen modeli poligon sayısının fazla ve doku boyutunun yüksek olmasından dolayı bu ortamlarda sunulmalarında kısıtlamaların meydana gelebileceği görülmektedir. Bu nedenle 3B model üzerinde doku ve poligon boyutunda düzenlemeler yapılarak veri çözünürlüğünün düşürülmesi veya modelin bir kesitinin sunulması gerekebilir.

3B veriler sahip oldukları yüzeylerden dolayı sanal uygulamalara entegre edilebilirken, nokta bulutu verileri ise herhangi bir yüzeye sahip olmadığından dolayı sanal platformlara entegre edilerek kullanılamamaktadır. Bununla birlikte yüzey dokusu ve poligon yapısından dolayı sanal platformlara 3B modellerin entegrasyonunda ise modellerin düzenlenerek veya modelin bir kısmının entegre edilmesi gerekmektedir.


VR uygulamaları kapsamında 3B kampüs modeli çevrimiçi platformlarda sanal gerçeklik gözlüğü ile kampüs üzerinde gezinerek 3B model üzerinde bulunan yapılara ve objelere etiketlenen bilgiler ile kampüse ait bilgiler görülebilmektedir. Ayrıca yurt, fakülte binalarının konumları, binalar arasındaki mesafeler, kampüs içi ulaşım hakkında bilgiler elde edilebilmektedir.

Sketchfab platformu, 3B modellerin ekran üzerinde gezinebilmesine olanak verdiği gibi sanal gerçeklik gözlüğü ile VR ortamında modellerin gezinebilmesine imkân sunmaktadır. Bu kapsamda, Sketchfab platformuna entegre edilen İTÜ Ayazağa Kampüsü 3B modellerinin, sanal gözlük ile gezilebildiği ve kampüs hakkında bilgi sağladığı görülmektedir (Şekil 11).



Şekil 11. 3B kampüs modelinin sanal gerçeklik ortamında görünümü (Sketchfab, 2022).

3B modeller kullanıcılara gezinerek bilgi vermenin dışında farklı uygulamalarda, etkinliklerde veya aktivitelerde kullanılabilir. İTÜ Ayazağa Kampüs 3B modeli sanal etkinliklerde (sinema, konser, mezuniyet, kış, mezuniyet vb. etkinlikler) kullanılabilir. Pandemi sürecinde çevrimiçi ortamda gerçekleştirilen etkinliklerin arttığı ve Metaverse kavramının kullanım alanlarının geliştirildiği görülmektedir. Metaverse kavramı kapsamındaki Sansar platformu, hazır olarak sunduğu 3B sanal ortamlarda, tasarlanmış veya İHA ile üretilen 3B modeller üzerinde etkinlikler gerçekleştirilebilmesine olanak sağlamaktadır (Sansar, 2022). Bu kapsamda, sanal etkinliklere imkân sunan sosyal sanal gerçeklik platformu olan Sansar platformuna İTÜ öğrenci kulüplerinin etkinlikleri kapsamında 3B kampüs modeline ait çeşitli 3B bina modelleri entegre edilmiştir. İTÜ öğrenci kulübü etkinliklerinden olan sinema günü, konser ve toplantı etkinlikleri çevrimiçi olarak sanal gerçeklik ortamında gerçekleştirilmiştir. Şekil 12’de Sansar platformunda, İTÜ Mustafa İnan Kütüphanesi 3B modelinde kış ortamı düzenlemeleri yapılarak konser etkinliği ve İTÜ Merkezi Derslik Binası (MED) 3B modeli üzerinden gerçekleştirilen sinema etkinliği görülmektedir. Bu etkinliklerde kullanıcılar hem bilgisayar üzerinden hem de sanal gerçeklik gözlüğü kullanımı ile katılımlarını gerçekleştirebilmektedir. Her kullanıcı bir karakter ile etkinliklere katılarak etkinlikte film izleme, müzik dinleme, sohbet etme ve toplantı gerçekleştirme işlemlerini çevrimiçi olarak sanal gerçeklik platformunda gerçekleştirebilmektedir.



Şekil 12. Sanal gerçeklik ortamında etkinliklerin gösterimi; a) İTÜ MED 3B modeli sinema etkinliği, b) İTÜ Mustafa İnan Kütüphanesi 3B modeli toplantı etkinliği (Sansar, 2022)

AR platformları, tasarlanan veya farklı metotlarla üretilen 3B modellerin kullanıcılara gerçek ortamda gösterilme olanağı sunmakla birlikte AR platformu olan Augment uygulaması, düşük boyuttaki verilerin ücretsiz olarak belirli sürede kullanıcılara sunulmasını sağlamaktadır (Augment, 2022). AR platformlarında da modellerin sahip olduğu yüksek üçgen modeli poligon sayısından dolayı verilerin görselleştirilmesinde hatalar verebileceği görülmektedir. Bu nedenle, İTÜ Ayazağa Kampüsü'ne ait bilgilerin artırılmış gerçeklikte sunulabilmesi amacıyla kampüse ait farklı bölge ve binalar ayrı olarak düzenlenerek artırılmış gerçeklik platformlarına aktarılmaktadır. Bu çalışmada, İTÜ Mustafa İnan Kütüphanesi, İTÜ MED binası ve İTÜ Stadyumu'na ait 3B modelleri Augment uygulamasına entegre edilerek kullanıcılara sunulmuştur (Şekil 13). Kullanıcılar, buldukları ortama mobil artırılmış gerçeklik uygulamaları ile 3B modelleri ekran üzerinde gezdebilmekte, inceleyebilmekte ve bilgi alabilmektedir. Ayrıca artırılmış gerçeklikteki modelin boyutunu düzenleyebilmekte ve ölçekli üretilen bir modelin gerçek yüzeyde ne kadar yer kaplayabileceğini de bu uygulamalar ile gözlemleyebilmektedirler.




Şekil 13. 3B modellerin artırılmış gerçeklikte sunumu; a) İTÜ Mustafa İnan Kütüphanesi, b) İTÜ MED binası, c) İTÜ Stadyumu 3B modelinin artırılmış gerçeklikte sunumu (Augment, 2022)

3.3 İHA Tabanlı Veri ile 3B Katı Model Üretimi

Gelişen teknoloji ile artık 3B modellerin 3B yazıcılar ile çıktıkları alınabilmektedir. İHA tabanlı üretilen 3B modeller yüksek çözünürlük ve doğruluklu veriler olmasından dolayı 3B katı modellerinin üretimlerinin gerçekleştirilebilmesi modelleme çalışmalarına farklı bir perspektif getirmektedir. Çizim programlarında binaların veya kampüs alanlarının modellerinin kalitesi, modellemeyi gerçekleştiren uzmanın tecrübe ve yeteneğine göre değişmektedir. Özellikle bina ve parça modellerinin için kullanılmakta olan bu teknolojiye İHA tabanlı üretilen verilerin entegrasyonu da gerçekleştirilmektedir.

Gerçeğe en yakın modelin üretilmesi kapsamında, İHA tabanlı 3B verilerin düzenlenerek katı modellerinin üretilmesi ve sunulması hem veri çözünürlüğü hem de modelleme zamanı ve maliyeti açısından avantaj sağlamaktadır. Bu kapsamda, İHA tabanlı İTÜ Ayazağa Kampüsü 3B modelinde bulunan İTÜ Mustafa İnan Kütüphanesi 3B modeli, 3B katı modelinin üretilmesi amacıyla düzenlenmiştir. 3B yazıcıların baskı boyutu ve süreleri dikkate alınarak kütüphane binasının 1/1.000 ölçekli modelinin Ultimaker 2+ Connect 3B yazıcı yüklenerek 3B katı model üretimi gerçekleştirilmiştir (Şekil 14). Üretilen modeller reklam, sunum veya anı eşyası olarak tasarlanarak kullanıcılara iletilebileceği görülmektedir. Ayrıca tarihi yapıların üretilen dijital ikizleri meydana gelebilecek bir yıkım sonucunda gelişen 3B baskı teknolojisi ile yeniden inşa edilebileceği yorumu yapılabilmektedir.



Şekil 14. İTÜ Mustafa İnan Kütüphanesi 3B katı modelinin farklı açılardan görünümü.

Hızlı ve düşük maliyetli olarak İHA ile üretilen 3B veriler düzenlenerek birçok uygulamanın altlığı olarak kullanıcıların farklı platformlarda erişimi sağlanarak gerçeğe yakın bilgi alınması ve gezilmesi sağlandığı görülmektedir.

4. Sonuçlar

Son yıllarda İHA'lar genellikle harita uygulamaları ve çalışmaları kapsamında veri üretimi amacıyla kullanıldığı görülmektedir. Gelişen teknoloji ile gerçeğe en yakın verinin İHA'lar ile iki ve üç boyutta elde edilmesiyle farklı birçok uygulamada verilerin değerlendirilebileceğini görülmektedir. Çalışmada, İHA uçşları sonucunda üniversite kampüsüne ait elde edilmiş farklı veri tiplerinin klasik haritalama uygulamaları dışında kullanımını gösterilmektedir. Ülkemizdeki ilk İHA ile kampüs çalışması olarak üniversite modellerinin oluşturulması kapsamında İTÜ Ayazağa Kampüsü'ne ait 3B modeli ve nokta bulutu verileri çevrimiçi platformlarda, farklı metaverse uygulamalarında erişime açılarak çevrimiçi ve sanal ortamdaki kullanıcılarla etkileşimi sağlamıştır. 3B katı model üretimi veya çevrimdışı platformlarda model sunumları ise kullanıcıların eğitim, gezme ve yapılar hakkında bilgi almak gibi farklı deneyimler yaşamasına olanak sağlayabilmektedir. Kampüs hakkında 3B yüksek çözünürlükteki görsel veri ile üniversite hakkında öznitelik, konum ve boyut gibi bilgilere erişim sağlanabilmektedir. Ayrıca İHA ile veri üretim süreçleri klasik veri üretim metodlarına göre daha hızlı ve güncellenebilir veriler sağlayabilmektedir. Dolayısıyla kampüse ait 3B veriler, zamansal olarak gerçekleştirilecek İHA uçşları ile hızlı bir şekilde güncellenerek sunulabileceği görülmektedir.

Günümüzde, Metaverse kavramı kapsamında geliştirilen platformlar doğrultusunda İHA tabanlı üretilen 3B verilerin farklı uygulamalara entegre edilebileceği görülmektedir. Bu kapsamda, yeryüzüne ait gerçeğe yakın bilgiler kullanıcılara sunulmakla birlikte yeryüzüyle dijital ortamda etkileşime girebilmeleri de sağlanmaktadır. 3B verilerin, metaverse kavramı doğrultusunda sanal gerçeklik, artırılmış gerçeklik uygulamaları, simülasyon platformları ve çevrimiçi uygulama gibi platformlarda sunulması ile kullanıcıların etkileşimi sonucunda gerçeğe en yakın deneyimin kullanıcılara kazandırılacağı ve doğru bilgiye hızlı erişimin sağlanabileceği görülmektedir.

Gerçekleştirilen çalışma ile farklı platformların İHA tabanlı 3B verilerin sunulmasına imkân verdiği görülmekle birlikte İHA tabanlı verilerin yüksek boyutlarına karşı olumsuz sonuçlar çıkarabildiği görülmektedir. Platformlarda bu verilerin sunulması için verilerin çözünürlüklerinin düşürülmesi ve verinin bir kısmının sunumun gerçekleştirilmesi sağlanabilmektedir. Bu platformlar için yeni veri üretim türü olan İHA'lar için gelişen teknoloji ile gelecekte güncellemeler ve geliştirmeler doğrultusunda İHA tabanlı bu verilerin yüksek hızda ve çözünürlükte kullanıcılara sunulacağı düşünülmektedir.

Teşekkür

Bu çalışmada verilerin temini ve işlenmesinde İTÜ Avrasya Yer Bilimleri Enstitüsü öğretim üyesi Doç. Dr. Orkan Özcan'a ve kurucusu olduğu Earth3Bee Lab. - 3 Boyutlu Yer Modelleme Laboratuvarı'na teşekkür ederim. Verilerin metaverse entegrasyonunda VRTLYN-Meta Architecture Platformu'na teşekkür ederim.

Kaynaklar

- Ağca, M., Gültekin, N., & Kaya, E. (2020). İnsansız hava aracından elde edilen veriler ile kaya düşme potansiyelinin değerlendirilmesi: Adam Kayalar Örneği, Mersin. *Geomatik*, 5(2), 134-145.
- Akay, S. S., Özcan, O., & Balık Şanlı, F. (2022). Quantification and visualization of flood-induced morphological changes in meander structures by UAV-based monitoring. *Engineering Science and Technology, an International Journal*, 27, 101106. doi: 10.1016/j.jestch.2021.05.020.
- Akay, S. S., & Ozcan, O. (2017). Volumetric Comparison of UAV-Based Point Clouds Generated from Various Softwares. In *International Symposium on GIS Applications in Geography and Geosciences, 2017. Proceedings.* (pp. 243).
- Andaru, R., Cahyono, B. K., Riyadi, G., Istarno Djurdjani Ramadhan, G. R., & Tuntas, S. (2019). The combination of terrestrial LIDAR and UAV photogrammetry for interactive architectural heritage visualization using unity 3D game engine. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, XLII-2(W17), 39-44.
- Augment. (2022, Haziran 22). *Augment platform*. Retrieved from <https://www.augment.com>
- Bayramoğlu, Z., & Uzar, M. (2023). Performance analysis of rule-based classification and deep learning method for automatic road extraction. *International Journal of Engineering and Geosciences*, 8(1), 83-97.
- Berrett, B. E., Vernon, C. A., Beckstrand, H., Pollei, M., Markert, K., Franke, K. W., & Hedengren, J. D. (2021). Large-Scale reality modeling of a university campus using combined UAV and terrestrial photogrammetry for historical preservation and practical use. *Drones*, 5(4), 136. doi: 10.3390/drones5040136.
- Cesium. (2022, Haziran 22). *Cesium platform*. Retrieved from <https://cesium.com/platform/cesium-ion/>
- Chang, Y.L., Hou, H.T., Pan, C.Y., Sung, Y.T., & Chang, K. (2015). Apply an augmented reality in a mobile guidance to increase sense of place for heritage places. *Educational Technology & Society*, 18(2), 166-178.
- Colomina, I., & Molina, P. (2012). Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79-97.
- DJI. (2022, Haziran 22). *DJI simulator platform*. Retrieved from <https://www.dji.com/simulator>
- Erdoğan, A., Kabadayı, A., & Akin, E.S. (2021). Kültürel mirasın fotogrametrik yöntemle 3B modellenmesi: Karabıyık Köprüsü örneği. *Türkiye İnsansız Hava Araçları Dergisi*, 3(1), 23-27.
- Gallo, I. G., Martínez-Corbella, M., Sarro, R., Iovine, G., López-Vinielles, J., Hernández, M., Robustelli, G., Mateos, R. M., & García-Davalillo, J. C. (2021). An Integration of UAV-Based Photogrammetry and 3D Modelling for Rockfall Hazard Assessment: The Cárcavos Case in 2018 (Spain). *Remote Sensing*, 13(17), 3450. doi: 10.3390/rs13173450.
- Gerloni, I. G., Carchiolo, V., Vitello, F. R., Sciacca, E., Becciani, U., Costa, A., ... & Tibaldi, A. (2018, September). Immersive virtual reality for earth sciences. In *2018 Federated Conference on Computer Science and Information Systems (FedCSIS), 2018. Proceedings.* (pp. 527-534). IEEE.
- İTÜ. (2022, Ekim 21). *Yerleşkelerimiz*. Retrieved from <http://tanitim.itu.edu.tr/kesfet/yerleskelerimiz>
- İTÜ Yeşil Kampüs. (2022, Ekim 10). *Yeşil kampüs*. Retrieved from <http://www.yesilkampus.itu.edu.tr/>
- ITUBEE. (2022, Haziran 22). *ITU3BEE sanal kampüs projesi*. Retrieved from <https://web.itu.edu.tr/ozcanork/ITU3BEE.html>
- Narin, N.G. (2021). A content analysis of the metaverse articles. *Journal of Metaverse*, 1(1), 17-24.
- Jaud, M., Grasso, F., Le Dantec, N., Verney, R., Delacourt, C., Ammann, J., Deloffre, J., & Grandjean, P. (2016). Potential of UAVs for monitoring mudflats morphodynamics (Application to the Seine Estuary, France). *ISPRS International Journal of Geo-Information*, 5(4), 50. doi: 10.3390/ijgi5040050.
- Javernick, L., Brasington, J., & Caruso, B. (2014). Modeling the topography of shallow braided rivers using structure-from-motion photogrammetry. *Geomorphology*, 213, 166-182.
- Halik, Ł., & Smaczyński, M. (2018). Geovisualisation of relief in a virtual reality system on the basis of low-level aerial imagery. *Pure and Applied Geophysics*, 175, 3209-3221.
- Hamal, S. N. G., Sarı, B., & Ulvi, A. (2020). Using of hybrid data acquisition techniques for cultural heritage a case study of Pompeiopolis. *Türkiye İnsansız Hava Araçları Dergisi*, 2(2), 55-60.
- Kalacska, M., Arroyo-Mora, J. P., & Lucanus, O. (2021). Comparing UAS LiDAR and Structure-from-Motion Photogrammetry for Peatland Mapping and Virtual Reality (VR) Visualization. *Drones*, 5(2), 36. doi: 10.3390/drones5020036.

- Laksono, D., Aditya, T., & Riyadi, G. (2019). Interactive 3D city visualization from structure motion data using game engine. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, XLII-4i(W16), 737-740.
- Lee, L.H., Braud, T., Zhou, P., Wang, L., Xu, D., Lin, Z., Kumar, A., Bermejo, C., & Hui, P. (2021). All one needs to know about metaverse: a complete survey on technological singularity, virtual ecosystem, and research agenda. *Journal of Latex Class Files*, 14(8), 1-66. doi: 10.48550/arXiv.2110.05352.
- Levine, N.M. & Spencer, B.F. Jr. (2022). Post-Earthquake Building Evaluation Using UAVs: A BIM-Based Digital Twin Framework. *Sensors*, 22(3), 873. doi: 10.3390/s22030873.
- Lucieer, A., Turner, D., King, D.H. & Robinson, S.A. (2014). Using an Unmanned Aerial Vehicle (UAV) to capture microtopography of Antarctic moss beds. *International Journal of Applied Earth Observation and Geoinformation*, 27, 53-62.
- Makineci, H. B. (2016). İnsansız hava araçları lidar etkileşimi. *Geomatik*, 1(1), 19-23.
- Maraş, E. E. & Nasery, N. (2023). Investigating the length, area and volume measurement accuracy of UAV-Based oblique photogrammetry models produced with and without ground control points. *International Journal of Engineering and Geosciences*, 8(1), 32-51.
- Mystakidis, S. (2022). Metaverse. *Encyclopedia*, 2(1), 486-497.
- Nex, F., & Remondino, F. (2014). UAV for 3D mapping applications: a review. *Applied Geomatic*, 6, 1-15.
- Özcan, O., Tari, U., Sunal, G., & Yalçın, C. (2022, May). Monitoring beachrock and low-altitude aerial photogrammetry-UAV in the northern coast of the Sea of Marmara, Turkey: A tool for coastal evolution and relative sea level change. In *24th EGU General Assembly, 2022*. doi: 10.5194/egusphere-egu22-5794.
- Özcan, O., & Özcan, O. (2021). Automated UAV based multi-hazard assessment system for bridges crossing seasonal rivers. *Smart Structures and Systems*. 27(1), 35-52.
- Özkaya, U., Makineci, H. B., Öztürk, Ş., & Orhan, O. (2021). Mozaiklenmiş insansız hava aracı görüntülerinde eksik bölgelerin örnekler iç boyaması ile elde edilmesi. *Geomatik*, 6(1), 61-68.
- Potree. (2022, Haziran 22). *Potree platform*. Retrieved from <https://potree.github.io/>
- Rezaldi, Y., Yoganingrum, A., Hanifa, N., Kaneda, Y., Kushadiani, S., Prasetyadi, A., Nugroho, B., & Men Riyanto, A. (2021). Unmanned aerial vehicle (UAV) and photogrammetric technic for 3D tsunamis safety modeling in Cilacap, Indonesia. *Applied Sciences*, 11(23), 11310. doi: 10.3390/app112311310.
- Rocca, R. (2021, March). Fault animation with 3D model integrating drone and satellite images. In *EGU General Assembly Conference, 2021. Proceedings*. doi: 10.5194/egusphere-egu21-8084.
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV flight experiments applied to the remote sensing of vegetated areas. *Remote Sensing*, 6(11), 11051-11080.
- Sansar. (2022, Haziran 22). *Sansar platform*. Retrieved from <https://www.sansar.com/>
- Scaravetti, D., & Doroszewski, D. (2019). Augmented Reality experiment in higher education, for complex system appropriation in mechanical design. *Procedia CIRP*, 84(2019), 197-202.
- Sefercik, U., Kavzoglu, T., Nazar, M., Atalay, C., & Madak, M. (2021). UAV-based 3D virtual tour creation. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVI-4(W5-2021), 493-499.
- Seki, M., Tiryakioğlu, İ., & Uysal, M. (2017). Farklı veri toplama yöntemleriyle yapılan hacim hesaplarının karşılaştırılması. *Geomatik*, 2(2), 106-111.
- Senkal, E., Kaplan, G., & Avdan, U. (2021). Accuracy assessment of digital surface models from unmanned aerial vehicles' imagery on archaeological sites. *International Journal of Engineering and Geosciences*, 6(2), 81-89.
- Shervais, S. (2016). *Structure from Motion guide for instructors and investigators*. Retrieved from https://d320goqmya1dw8.cloudfront.net/files/getsi/teaching_materials/high-rez-topo/sfm_guide_instructors_investigators.v2.pdf
- Sketchfab. (2022, Haziran 22). *Sketchfab platform*. Retrieved from <https://sketchfab.com>
- Snavely, N., Seitz, S. M., & Szeliski, R. (2007). Modeling the world from internet photo collections. *International Journal of Computer Vision*, 80(2), 189-210.
- Şasi, A., & Yakar, M. (2018). Photogrammetric modelling of Hasbey Dar'ülhuffaz (Masjid) using an unmanned aerial vehicle. *International Journal of Engineering and Geosciences*, 3(1), 6-11.
- Şenol, H.İ., Yiğit, A.Y., Kaya, Y., & Ulvi, A. (2021). İHA ve yersel fotogrametrik veri füzyonu ile kültürel mirasın 3 boyutlu (3B) modelleme uygulaması: Kanlıdivane Örneği. *Türkiye Fotogrametri Dergisi*, 3(1), 29-36.
- Qin, R., Gruen, A., & Huang, X. (2012, November). UAV project-building a reality-based 3D model of the NUS (National University of Singapore) campus. In *33rd Asian Conference on Remote Sensing, 2012. Proceedings*. (pp. 26-30).
- Teke, T. (2016). *Unmanned aerial vehicle based visualization of deep excavations using game engines* (Doktora Tezi). Ortadoğu Teknik Üniversitesi, Ankara.
- Turner, I. L., Harley, M. D., & Drummond, C. D. (2016). UAVs for coastal surveying. *Coastal Engineering*, 114, 19-24.

- Ulvi, A., & Toprak, A. S. (2016). Investigation of three-dimensional modelling availability taken photograph of the unmanned aerial vehicle; sample of Kanlıdivane Church. *International Journal of Engineering and Geosciences*, 1(1), 1-7.
- Ulvi, A. (2018). Analysis of the utility of the unmanned aerial vehicle (UAV) in volume calculation by using photogrammetric techniques. *International Journal of Engineering and Geosciences*, 3(2), 43-49.
- Ulvi, A., Yakar, M., Yiğit, A. Y., & Kaya, Y. (2020). İHA ve Yersel Fotogrametrik Teknikler Kullanarak Aksaray Kızıl Kilisenin 3b Modelinin ve Nokta Bulutunun Elde Edilmesi. *Geomatik*, 5(1), 19-26.
- Yakar, M., Kabadayı, A., Yiğit, A. Y., Çıkıkcı, K., Kaya, Y., & Catin, S. S. (2016). Emir Saltuk Kümbeti fotogrametrik rölöve çalışması ve 3boyutlu modellenmesi. *Geomatik*, 1(1), 14-18.
- Yang, J., Yan, G., & Geng, P. (2021, February). Study on 3D printing based on UAV oblique photogrammetry. In *IOP Conference Series: Earth and Environmental Science*, 676, 012010. doi: 10.1088/1755-1315/676/1/012010.
- Weißmann, M., Edler, D., & Rienow, A. (2022) Potentials of low-budget microdrones: processing 3d point clouds and images for representing post-industrial landmarks in immersive virtual environments. *Frontiers in Robotics and AI*, 9, 886240. doi: 10.3389/frobt.2022.886240.
- Woodget, A.S., Carbonneau, P.E., Visser, F., & Maddock, I. P. (2015). Quantifying submerged fluvial topography using hyperspatial resolution UAS imagery and structure from motion photogrammetry. *Earth Surface Processes and Landform*, 40(1), 47-64.

İstatistiksel Yöntemlerle Yukarı Karasu Havzası'nın Kuzeydoğu Bölümünün (Erzurum) Heyelan Duyarlılık Analizi

Landslide Susceptibility Analysis of the Northeastern Part of the Upper Karasu Basin (Erzurum) Using Statistical Methods

Erdem Aydoğan¹, Serhat Dağ^{2*}

¹Afet ve Acil Durum (AFAD) İl Müdürlüğü, Erzurum/Türkiye.

²Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Jeoloji Mühendisliği Bölümü, 29000, Gümüşhane/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Serhat Dağ
serhatdag@gumushane.edu.tr

doi: 10.48123/rsgis.1202140

Yayın süreci

Geliş tarihi: 10.11.2022
Kabul tarihi: 07.02.2023
Basım tarihi: 28.03.2023

Özet

Bu çalışmada, Erzurum ilinde Yukarı Karasu Havzası'nın kuzeydoğu bölümünün heyelan duyarlılık analizi gerçekleştirilmiştir. Arazi çalışmaları ile 334 adet heyelan tespit edilerek heyelan envanter haritası oluşturulmuştur. Mevcut heyelanların %80'i analizlerde kullanılırken, rastgele seçilen %20'si ise duyarlılık performansının değerlendirilmesinde kullanılmıştır. Çalışma alanı koşulları göz önünde bulundurularak jeolojik, topoğrafik ve çevresel parametreler analizlerde değerlendirilmiştir. Çalışmada hem frekans oranı yöntemi (FO) hem de Bayes olasılık modeli (BO) kullanılarak 5 farklı duyarlılık sınıfından oluşacak şekilde heyelan duyarlılık haritaları üretilmiştir. Daha sonra haritalar mevcut heyelanlarla karşılaştırılarak performans analizi gerçekleştirilmiştir. Frekans oranı yöntemine göre çalışma alanının %55.02'si, mevcut heyelanların ise %89.1'i yüksek ve çok yüksek duyarlı alanlar olarak belirlenmiştir. Bayes olasılık modeli ile üretilen duyarlılık haritasında ise çalışma alanının %41.21'i, mevcut heyelanların ise %76.45'i yüksek ve çok yüksek duyarlı alanlarda tespit edilmiştir. Bu sonuç çalışmada her iki yöntemle elde edilen heyelan duyarlılık haritalarının mühendislik projelerinin tasarımı ve mekânsal planlama çalışmalarında kullanılabilir nitelikte olduğunu göstermektedir.

Anahtar kelimeler: Heyelan, Frekans oranı yöntemi, Bayes olasılık modeli, Yukarı Karasu havzası, Erzurum, Duyarlılık analizi

Abstract

In this study, a landslide susceptibility analysis was carried out in the northeastern part of the Upper Karasu Basin in Erzurum. 334 landslides were determined by field studies and a landslide inventory map was created. While 80% of the existing landslides were used in the analyses, the randomly selected 20% were used in the evaluation of the susceptibility performance. Considering the conditions of the study area, geological, topographic and environmental parameters were evaluated in the analysis. The landslide susceptibility maps were produced using both the Frequency ratio method (FR) and Bayesian probability modal (BM), consisting of five susceptibility classes. Then, performance analysis was performed by comparing these maps with the existing landslides. According to the frequency ratio method, 55.02% of the study area and 89.1% of the existing landslides were determined as high and very high susceptible areas. However, in the susceptibility map produced by the Bayesian probability model, 41.21% of the study area and 76.45% of the existing landslides were detected in high and very high susceptible areas. This result shows that the landslide susceptibility maps obtained by both methods can be used in the design of engineering projects and spatial planning studies.

Keywords: Landslide, Frequency ratio method, Bayesian probability model, Upper Karasu basin, Erzurum, Susceptibility analysis

1. Giriş

Üzerinde yaşadığımız dünyanın atmosferle etkileşimi ve iç yapısının dinamik olması dolayısıyla doğa olayları olarak adlandırılan deprem, heyelan, taşkın ve çığ türü olaylar meydana gelmektedir. Dünya genelinde, özellikle son 30 yıllık dönemde, nüfustaki hızlı artış, yeryüzü dinamikleri ve küresel iklim değişikliği gibi nedenlerin etkisi ile afete dönüşen doğa olaylarının sayısında kayda değer artışlar gözlenmektedir. Bu tür olaylar, insan hayatında ve çevresel koşullarda olumsuz yönde etkiye sahip olmaları durumunda afet olarak adlandırılmaktadır. Dünya genelinde uzun dönem ortalamaları dikkate alındığında depremlerden sonra hasar verebilme potansiyeli ve can kaybı en yüksek afet türü heyelanlardır (Gökçe vd., 2008; Aydođan, 2019). Jeolojik, jeomorfolojik ve meteorolojik koşulların heyelan oluşumu üzerindeki etkinliği dikkate alındığı zaman dünya üzerindeki birçok ülkenin heyelan afeti ile karşı karşıya olduğu rahatlıkla ifade edilebilir. Özellikle son yıllarda küresel iklim değişikliklerine bağlı olarak dünyadakine benzer şekilde ülkemizde oluşan heyelan kaynaklı afetler de aşırı yağışlar ya da depremlerin tetiklenmesi sonucunda meydana gelmektedir.

Heyelanlardan kaynaklı maddi zararlar dikkate alındığında sahip oldukları jeolojik, morfolojik ve meteorolojik koşullar nedeniyle çok fazla sayıda afet olayına maruz kalan İtalya, İsviçre ve ABD gibi gelişmiş ülkeler güçlü ekonomileri sayesinde afetlerin olumsuz etkilerinden daha az etkilenmektedir. Buna rağmen benzer afetler daha az meydana gelmesine rağmen az gelişmiş ve gelişmekte olan ülkelerde daha büyük çevresel zararlar oluşturmakta ve ülke ekonomilerini önemli derecede etkilemektedir. Az gelişmiş ve gelişmekte olan ülkeler bir yıldaki üretimlerinin %1-2'sini afetler sonucunda kaybetmektedirler. Yine Dünya Bankası verileri dikkate alındığında afetlerden kaynaklı can kaybının %95'i bu tür ülkelerde gerçekleşmektedir (Kremier ve Arnould 2000; Aydođan, 2019). Sahip olduğu jeolojik özellikler, coğrafi yapısı ve iklimsel koşullar nedeniyle afetlere sık sık maruz kalan ülkemizde gerçekleşen deprem, heyelan ve taşkın türü olaylara bağlı afetler sonucu önemli miktarda can ve mal kaybı yaşanmaktadır. Bunlar içerisinde heyelan olayları neticesinde yaşanan kayıplar genellikle heyelanları tetikleyen deprem ve aşırı yağış gibi süreçlerin içerisinde değerlendirildiğinden çoğu zaman değerlendirmelerin gerçek durumu yansıtmakta yetersiz kaldığı, heyelan kaynaklı zararların gerçek boyutlarının daha da yüksek olduğu düşünülmektedir (Derin ve Ercanođlu, 2018). Bunun yanı sıra heyelan kaynaklı afet olayları sonucunda ölüm ya da yaralanma ile ilgili sayılar çoğunlukla aşırı yağışlar ve deprem, daha az oranda ise diğer doğa veya insan kaynaklı birincil olaylara atfedilmektedir (Fidan ve Görüm, 2020). Yine olaydan etkilenen yaralı ve kayıp kişilerin durumlarının sonradan güncellenmemesi gibi nedenler dolayısıyla aslında çoğu zaman heyelanlar kaynaklı kayıp ve zararların gerçek boyutları tahmin edilenden daha yüksektir (Schuster, 1996; Haque vd., 2019; Fidan ve Görüm, 2020). Artan nüfus, şehirleşmelerde yaşanan düzensizlikler, teknolojik gelişmelere bağlı olarak farklı mühendislik yapılarına olan gereksinimin artması gibi birçok neden önümüzdeki yıllar için heyelanlardan kaynaklı afetler neticesinde yaşanabilecek kayıpların giderek çoğalacağını, dolayısıyla da bu alanda detaylı bilimsel çalışmaların önemi ve gerekliliğini de zorunlu kılmaktadır (Dađ ve Bulut, 2012). Doğa olayları ve sonucunda yaşanan afetler, ülkemiz açısından son derece önemli bir sorundur. Afetlerden kaynaklanan zararlar içerisinde değerlendirilen doğa olaylarına bağlı yaşanan can kaybı ve maddi kayıpların en az seviyeye indirgenmesi amacı ile çok sayıda araştırma yapılmaktadır (Dađ vd., 2011). Bu açıdan ele alındığında, ülkemizde Afet ve Acil Durum Yönetim Başkanlığı (AFAD), Maden Tetkik ve Arama Genel Müdürlüğü (MTA) gibi devlet kurumları ile üniversiteler ve özel kuruluşlar tarafından, özellikle son yıllarda önemli projeler gerçekleştirilmektedir. Yine ülkemizde konu ile ilgili araştırmacıların Web of Science tarafından taranan dergilerde yapmış oldukları heyelan duyarlılığı, tehlike ve riskine yönelik makale çalışmaları bu anlamda azımsanmayacak seviyededir (Derin ve Ercanođlu, 2018).

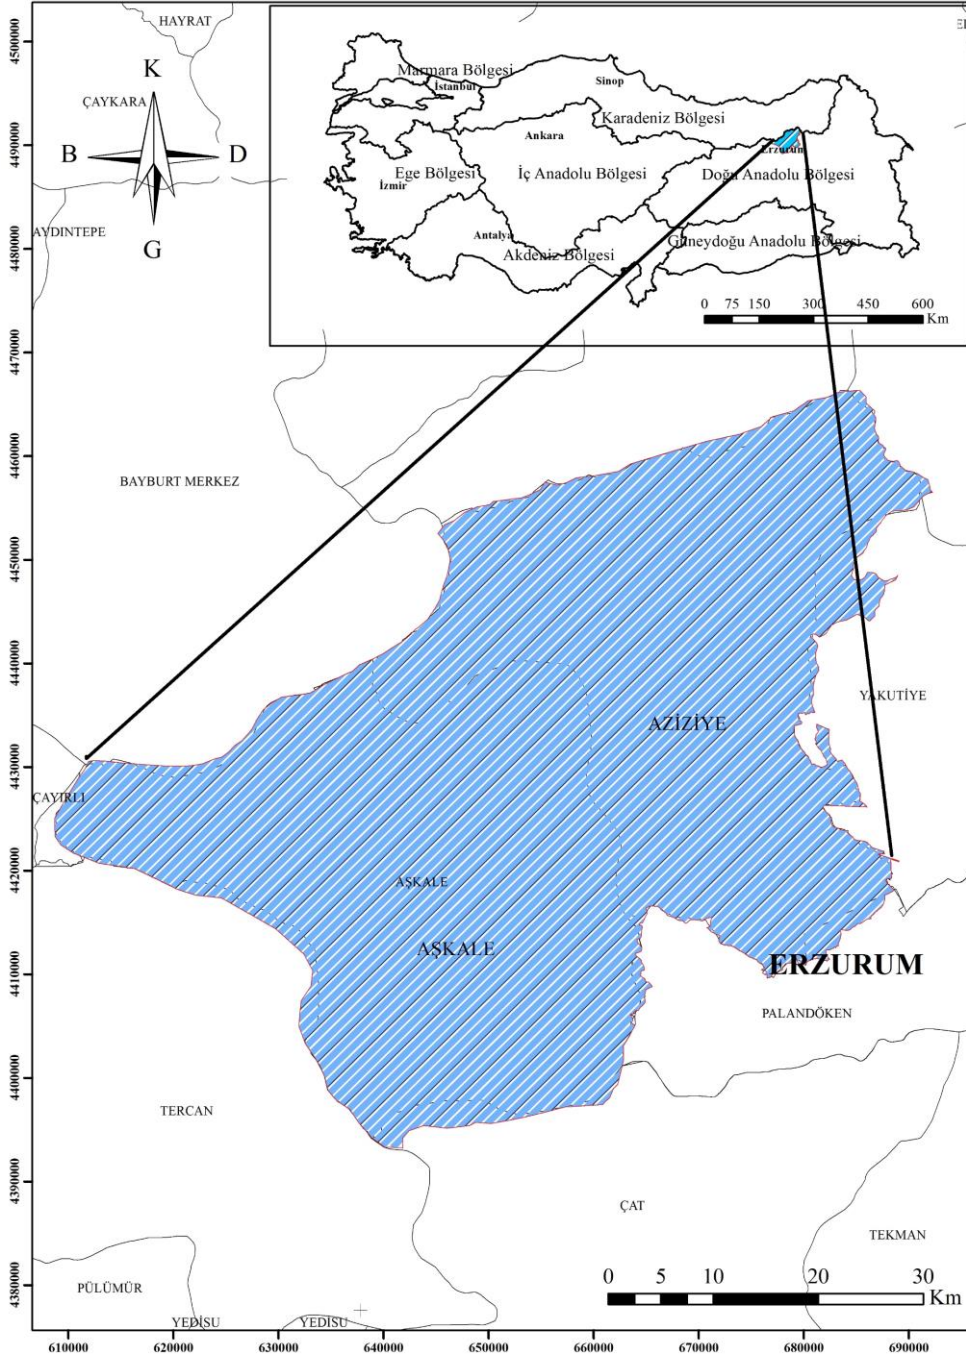
Baraj yeri, depolama alanı, yerleşim yeri gibi yer seçimi çalışmaları ile demir yolu ve kara yolları, oto yollar gibi güzergâh belirlemeye yönelik çalışmalar ya da buna benzer mühendislik projelerinin gerçekleştirilmesi aşamalarında ilgili alanların heyelan duyarlılığı açısından değerlendirilmesi önemlidir. Bu şekilde yüksek maliyet gerektiren bu tür projelerde ileride heyelan nedeniyle yaşanabilecek olumsuzlukların da önüne geçilmiş olacaktır (Akgün, 2018).

Bölgesel açıdan değerlendirilecek olursa, Karadeniz Bölgesi ve Dođu Anadolu Bölgesi ülkemizde heyelanlar açısından en fazla olay sayısına sahip bölgelerdir. AFAD verilerine göre, heyelan türü afet olay sayısı dikkate alındığında, Trabzon 1123 olay sayısı ile ilk sırada yer almaktadır. Olay sayısında Trabzon'u 1049 heyelan ile Rize, 613 ile Kastamonu ve 573 heyelanla Erzurum takip etmektedir. Aynı dönem içerisinde ülke genelinde kayıt altına alınmış olan heyelan olay sayısı ise 13494'tür (Gökçe vd., 2008; Aydođan, 2019). Karadeniz Bölgesi'nde gerçekleşen heyelanlarının büyük bir çoğunluğu aşırı yağışlara bağlı olarak gelişen sığ akma ve kayma türündeki heyelanlardır. Dođu Anadolu Bölgesi'nde ise yüksek kesimlerdeki ani kar erimelerinin büyük ölçekli heyelanlar açısından tetikleyici unsur olduğu, ayrıca yörenin depremselliğinin de yine heyelanları tetikleyerek afetlere sebebiyet verdiği düşünülmektedir.

Bu durumlar dikkate alınarak gerçekleştirilen bu çalışma ile öncelikle heyelanlara bağlı yaşanacak can kaybı ve maddi kayıpların en az seviyeye indirgenmesi amaçlanmıştır. Bunun yanı sıra nüfus artışları nedeniyle ihtiyaç olan yeni yerleşim alanı seçimine yönelik çalışmalar ile sanayi ve mühendislik yapı alanlarının tasarımında da faydalı olması amacıyla iki farklı istatistiksel yöntem kullanılarak Yukarı Karasu Havzası'nın kuzeydođu bölümünün heyelan duyarlılık haritaları üretilmiştir.

2. Çalışma Alanı ve Jeolojisi

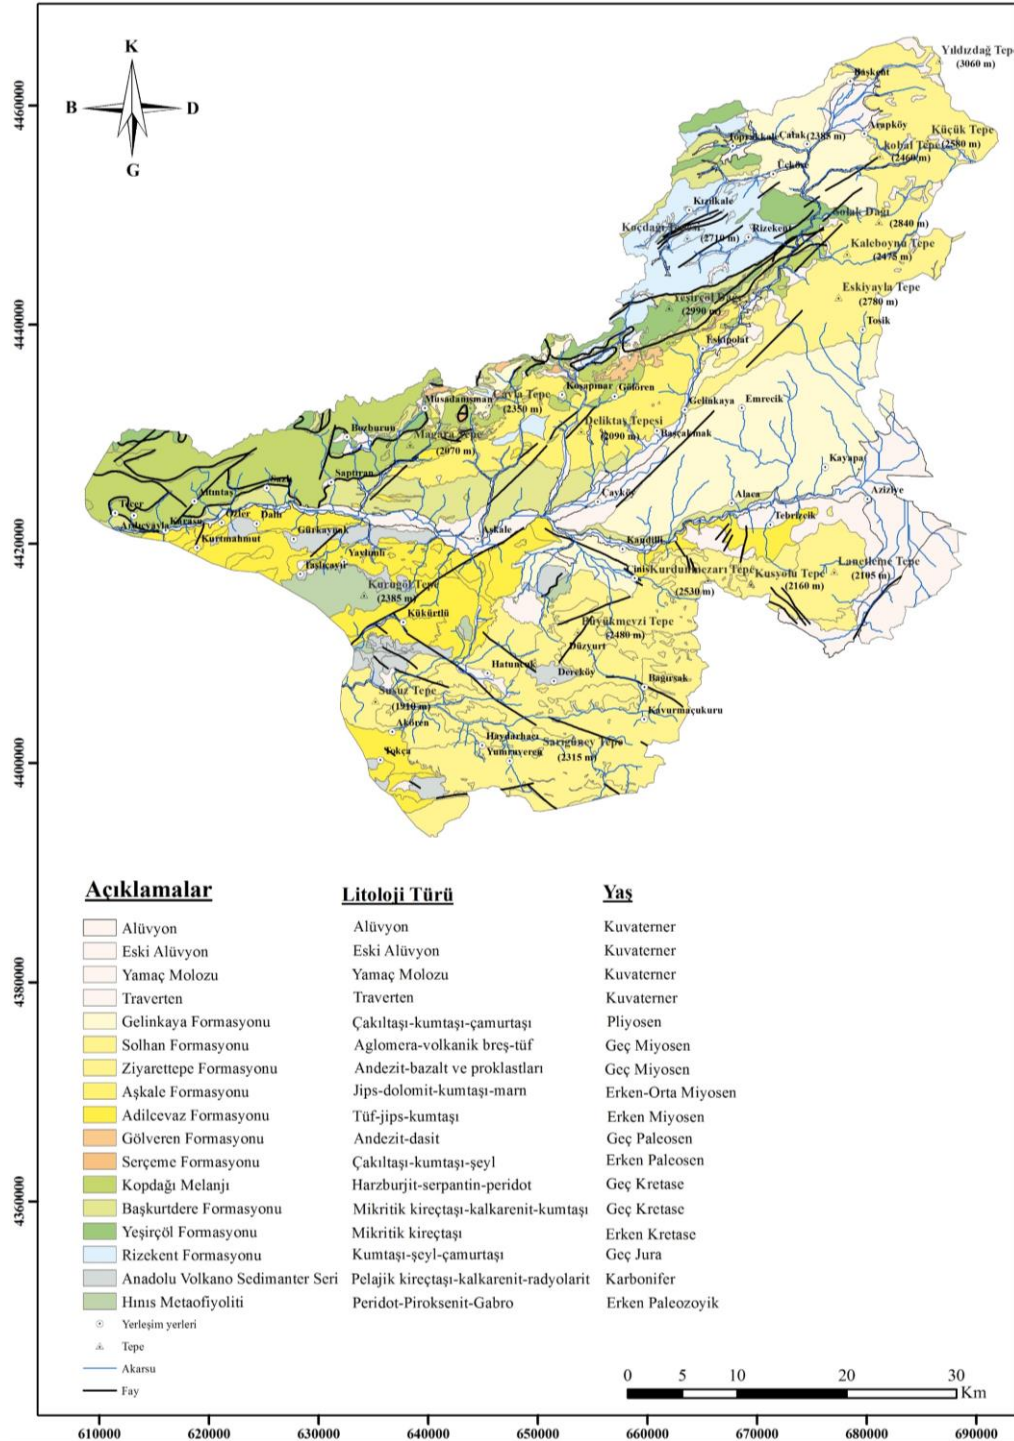
Çalışma alanı, Yukarı Karasu Havzası'nın kuzeydođu bölümünden oluşmaktadır. Bu bölüm Dođu Anadolu Bölgesi'nde Aziziye ve Aşkale (Erzurum) ilçe sınırları içerisinde yer almaktadır. Çalışma alanının sınırları 1/25000 ölçekli 32 adet paftadan Yukarı Karasu Havzası'nın genel sınırları ile Aziziye ve Aşkale ilçelerinin idari sınırlarının kesişimi dikkate alınarak elde edilmiştir (Şekil 1). Karasu Nehri'nin çıkış yeri Erzurum Ovası'nda bulunan Kargapazarı Dađları'dır. Bu nehir aynı zamanda Fırat Nehri'nin de ana kaynađını oluşturmaktadır (Aydođan, 2019).



Şekil 1. Çalışma alanına ait yer bulduru haritası

Aziziye ilçesi Erzurum Büyükşehir Belediyesi'ne bađlı merkez ilçelerden biri olup, il merkezine 15km mesafededir. E80 Devlet karayolu ile ulaşımın sağlandığı Aşkale ilçesi ise Erzurum'a 54 km uzaklıkta olup, il merkezinin batısında yer almaktadır.

Çalışmaya konu olan bölgede vadi tabanları, aşınım yüzeyleri, tepelik alanlar ve taraçalar gibi morfolojik birimler yer almaktadır. Oldukça kırıklı ve kıvrımlı olan dağların büyük bir kısmı Alpin orojenezine bağlı olarak neotektonik hareketler neticesinde şekillenmiştir. Morfolojik yapılar içerisinde dağlar kadar geniş yer kaplamamakla birlikte Ovacık (Ilıca) Platosu bulunmaktadır. Yükselti değerleri 1200-2200m arasında değişen Erzurum ve Aşkale Ovaları tektonik kökenli olup, çalışma alanında yer alan en önemli ovalarıdır. Havzanın hemen doğusunda yer alan Erzurum Ovası 591 km²lik yüzölçümüne sahiptir. Ovanın farklı bölgeleri dikkate alındığında deniz seviyesinden yüksekliği 1750-2050 m arasında değişmekte olup sık sık faylarla kesilmektedir. Havzanın hemen güneybatısında yer alan Aşkale Ovası yaklaşık 26 km² yüzölçümüne sahip olup, Pırnakapan, Koşapınar gibi bazı yerleşim yerleri ile Gölveren ve Ballıtaş Mahalleleri heyelan olaylarına maruz kalan alanlardır. Yöre çoğunlukla jipsli ve killi birimlerden oluşmaktadır. Özellikle fay hatlarına yakın alanlar ile akarsu vadilerinin geçtiği alanlarda yaygın olarak heyelanlar gözlenmektedir.



Şekil 2. Çalışma alanının jeoloji haritası (Tarhan (1990;1998) ve Timur (2000)'den yararlanarak)

Erzurum Meteoroloji İstasyon verilerine göre yörede yıllık ortalama yağış 432 mm'dir. Bu verilere göre 73.8 mm ile Mayıs ayı en yüksek, 17.7 mm yağış ile Ağustos ayı ise en düşük yağış ortalaması değerine sahip aylardır. Çalışma alanında özellikle kış aylarında ve yüksek kesimlerde kar yağışı etkilidir. Ocak ve Şubat ayları 11'er gün süre ile karın en çok yağdığı iki aydır ve bu aylarda yağın kar uzun süre erimemektedir.

Çalışmada daha önce Tarhan (1990;1998) tarafından hazırlanan haritalardan ve Timur (2000) tarafından bölgede gerçekleştirilen stratigrafi çalışmalarından yararlanılmıştır. Bu çalışmalar esas alınarak çalışma alanının jeoloji haritası hazırlanmıştır (Şekil 2).

Yukarı Karasu Havzası içerisinde bulunan litolojik birimler erken Paleozoikten günümüze kadar değişen bir yaş aralığına sahiptir. Çalışma alanında peridotit, piroksenit, olivinli gabro ve levha dayk karmaşığından oluşan Erken Paleozoik yaşlı Hınıs Metaofiyolitleri tabanı oluşturmaktadır ve Tarhan (1989) tarafından tanımlanmıştır. Bu birimin üzerine ofiyolitli melanj veya ofiyolitli karışık olarak tanımlanan, Karbonifer-Geç Kretase yaşlı Anadolu Ada Yayı Volkanoklastik Sedimanter Serisi gelmektedir (Tarhan, 1998). Bu birim üzerinde, kumtaşı, şeyl, çakıltaşı, kireçtaşı ve volkanik araseviyelerinden oluşan Rizekent Formasyonu bulunmaktadır. Bu formasyona Timur (2000) tarafından Geç Jura yaşı verilmiştir. Rizekent Formasyonu'nun üzerine Yeşilçöl Formasyonu gelmektedir. Bu formasyon bol çörtlü açık renkli kireçtaşları ile ara seviyeler halinde marn ve yeşilimsi gri renkli kalkarenitlerden oluşmaktadır. Bu formasyona içerisinde bulunan fosillere dayanarak Timur (1997) tarafından Erken Kretase yaşı verilmiştir. Çalışma alanında Akdeniz vd. (1994) tarafından Başkurtdere Formasyonu olarak isimlendirilen bir diğer formasyon ise kumtaşı, mikritik kireçtaşı, yeşilimsi marn, kalkarenit, ve şeyl ardalanması ile yüzeylenmektedir. Timur (2000) tarafından biyomikritlerde tespit edilen fosillere dayanılarak formasyona Geç Kretase yaşı verilmiştir. Başkurtdere Formasyonu'nun üzerine mafik ve ultramafik kayalardan oluşan Kopdağı Melanjı gelmektedir. Formasyon içerisinde hâkim kaya türü peridotit ve piroksenitlerdir. Bölgesel deneştirme ve birimlerin alt-üst ilişkisinden yararlanarak birime Malm-Geç Kretase yaşı verilmiştir (Timur, 2000). Bu birimin üzerine çakıltaşı, kumtaşı, şeyl ve kireçtaşlarından oluşan Serçeme Formasyonu gelmektedir. Serçeme Formasyonu'na içermiş olduğu fosillerden hareketle Timur (1997) tarafından Senoniyen-Erken Paleosen yaşı verilmiştir. Aglomera, tuf, andezit ve dasitik piroklastitlerinden oluşan Gölveren Volkanitleri, Kopdağı Melanjı ve Serçeme Formasyonu'nu keserek bu birimleri üstlemekte olup birimin yaşı Geç Paleosen-Erken Eosen'dir (Timur, 2000). Erzurum ve çevresinde geniş yayılım gösteren Adilceva Formasyonu volkanik arakatlı resifal kireçtaşı, kumtaşı, çakıltaşı, tuf, tüfit, kalkarenit, marn ve yer yer jips-anhidrit-tuz türü kayalardan oluşmaktadır. Birime Tarhan (1990) tarafından Erken Miyosen yaşı verilmiştir. Adilceva Formasyonu üzerine çalışma alanının kuzey kesiminde sığ denizel çökellerden oluşan Erken-Orta Miyosen yaşlı Aşkale Formasyonu gelmektedir (Timur, 1997). Aşkale Formasyonu çalışma alanında KD-GB doğrultusunda bir hat boyunca uzanmakta ve Gürleyintepe, Koşapınar ve Meymansur olarak adlandırılan üç alt üyeden oluşmaktadır. Aşkale Formasyonu'nun üzerinde gri siyah renkli andezit, bazalt ve bunların piraklastitlerinden oluşan ve bu birimi keserek yerleşen Geç Miyosen yaşlı Ziyarettepe Volkanitleri yer almaktadır (Timur, 2000). İnceleme alanında güney kısımlarda yer yer ince orta tabakalı marn, gösel kireçtaşı ve çakıltaşı arakatlı aglomera ve volkanik breş içeren birim Solhan Formasyonu olarak adlandırılmakta olup, Geç Miyosen yaşındadır (Tarhan, 1998). Çalışma alanında Formasyon mertebesinde en genç birim Pliyosen yaşlı Gelinkaya Formasyonudur. Bu formasyon, tüfit araseviyeleri kumtaşı, çakıltaşı, kiltası ve marn ardalanması ile tipiktir. Akarsu ve dere yataklarında çevre kayaların kırıntılarında oluşan, bloktan kil boyutuna kadar değişen boyutlarda malzeme içeren alüvyonlar Kuvaterner yaşlı olup, çalışma sahasındaki traverten ve yamaç molozları ile birlikte en genç birimleri oluşturmaktadır (Aydođan, 2019).

3. Heyelan Duyarlılık Analizleri

Çalışma alanında heyelan duyarlılık haritasının üretilmesi için hem parametre hem de yöntem seçimi önemlidir. Parametre seçiminde en önemli unsur yamaçların dengesini etkileyen, bölgede heyelan oluşumunda etkili olan ve haritalanabilecek nitelikteki parametrelerin seçimidir. Bununla birlikte çalışma alanının büyüklüğü ya da çalışma ölçeğı, veri elde etmede kullanıcıların karşılaşılabileceğı sorunlar ile çalışma alanına özgü durumlardan kaynaklanan parametrenin etkinliği gibi hususlar hangi parametrelerin duyarlılık haritası üretiminde kullanılacağı sorusunun cevaplarını oluşturmaktadır (Gökçeođlu ve Ercanođlu, 2001; Dađ, 2007; Dađ vd., 2011). Aslında daha az oranda kullanılan litoloji-ayırışma, ayırışma derinliği, çizgisel unsurlara yakınlık, zemin makaslama dayanımı gibi bazı parametreler çalışılan alanın özelliklerine bağılı olup, ilgili alan için heyelan oluşumu açısından büyük öneme sahip olabilmektedir (Dađ vd., 2021). Nitekim konuya yönelik çalışmalarda kullanılan parametrelerin seçimi yapılırken çalışma alanındaki heyelanların gelişim sürecini önemli ölçüde denetleyen unsurlar gözetilmektedir (Gökçeođlu ve Ercanođlu, 2001). Bu değerlendirmeler dikkate alınarak çalışma alanı için hazırlayıcı faktörlerden jeolojik faktör olarak litoloji kullanılmıştır. Topoğrafik faktör olarak yükseklik, yamaç eğimi, yamaç eğim yönü, yamaç eğriselliğı ve akarsuya yakınlık dikkate alınmıştır. Çevresel parametrelerden ise arazi kullanımı ve ana faya yakınlık unsurları bu çalışma için heyelan oluşumunda etkili olarak değerlendirilmiş ve heyelan duyarlılık haritalarının üretiminde kullanılmıştır.


Heyelan duyarlılık haritalarının üretilmesinde genel anlamda nitel ve nicel yöntemlerden yararlanılmaktadır. Sayısal olmayan yöntemler, daha çok doğrudan saha gözlemlerini esas alan ve duyarlılık değerlendirmesini yapan kişinin bilgi ve deneyiminin ön plana çıktığı yöntemlerdir. Bu tür yöntemlerde çalışmaya esas olan verilerin temel kaynağını arazi çalışmaları esnasındaki gözlem ve değerlendirmeler oluşturmaktadır. Bu yöntemde arazi çalışmalarına ilaveten hava fotoğrafları yorumlanarak duyarlılık değerlendirmesi gerçekleştirilmektedir. Sayısal yöntemlerde ise heyelana neden olabilecek çok sayıdaki parametre bilgisayar ortamında analiz edilerek duyarlılık haritaları üretilmektedir. Bu yöntemlerde, ortam koşulları ile heyelanların oluşumu arasındaki ilişki matematiksel işlemlere dayanarak sayısal olarak ortaya koyulmaktadır. Jeoteknik yaklaşımlar, veri kaynaklı istatistiksel yöntemler ile yapay sinir ağları, bulanık mantık gibi yapay zekâ yöntemleri analizlerde kullanılan sayısal yöntemler içerisinde yer almaktadır. Bu çalışmada ayrıntıları ilerleyen bölümlerde verilen istatistiksel yöntemlerden Frekans oranı yöntemi (FO) ve Bayes olasılık modeli (BO) kullanılmıştır.

3.1. Heyelan Envanteri

Heyelan duyarlılık değerlendirmelerinin yapılabilmesi açısından çalışma alanındaki heyelanların mekânsal dağılımının yanı sıra tipleri ve mümkünse zamansal değişimlerinin de gösterildiği heyelan envanter haritalarının hazırlanması çok önemlidir. Bu sayede güvenilir bir veri tabanı oluşturulabilir. Sonraki aşamalarda üretilecek haritaların kullanılabilirliği veri miktarı ve niteliğine bağlıdır. Heyelan envanterine yönelik yapılacak hatalar, sonrasında oluşturulacak duyarlılık haritalarının da doğruluğunu direkt etkileyecektir (van Westen, 1994).

Çalışmanın amacı, veri kaynağı ve çalışma ölçeği heyelan envanterini oluşturulurken araştırmacıların ne tür bir yol izlemesi gerektiği ve yöntem hususunda belirleyici olmaktadır. Literatür çalışmalarına dayalı tarihsel kayıtların incelenmesi, farklı zamanlara ait hava fotoğraflarının yorumlanması, arazi çalışmaları ile kontrol ve doğrulamaların yapılması özellikle öncü çalışmalarda sıklıkla tercih edilen yöntemlerdir. Daha sonraları ise teknolojik gelişmelere de bağlı olarak GIS ve CAD tabanlı yazılımların yaygınlaşması ve uydu görüntülerinin hassasiyetinin artması envanter çalışmalarına önemli katkılar sağlamıştır.

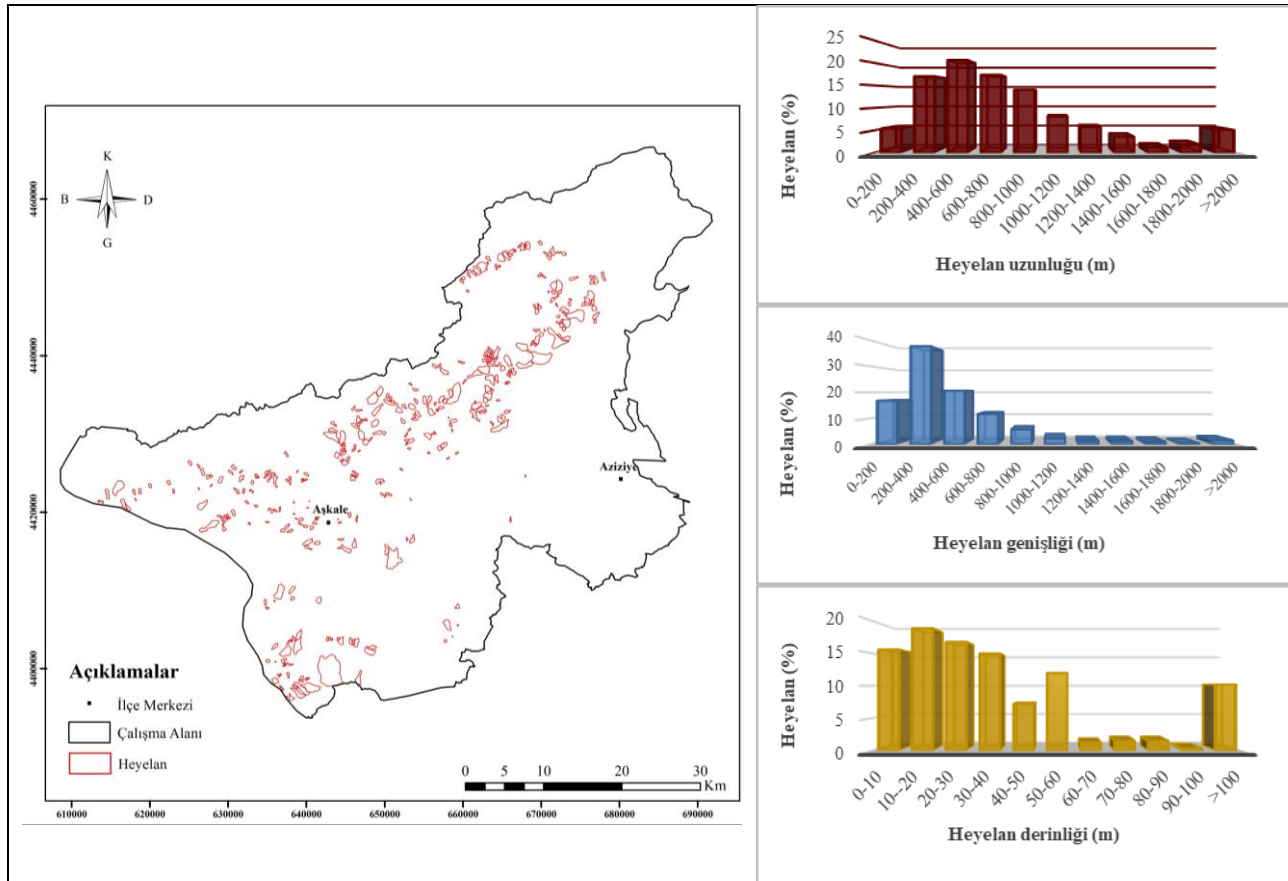
Çalışmada Erzurum İl Afet ve Acil Durum Müdürlüğü tarafından 2016 yılında hazırlanan heyelan envanter haritasına ilişkin çalışmalar esas alınmıştır. Bu çalışmada ise özellikle arazide heyelanların tipi, boyutları, koordinatları gibi bir takım tanımlayıcı bilgileri tespit edilmiş ve gerekli kontrollerle birlikte heyelan envanteri güncellenmiştir. Büyük çoğunluğu toprak kayması şeklinde gerçekleşen heyelanlar içerisinde yer yer moloz akmaları ve çoklu hareketlerin de gerçekleştiği gözlenmiştir (Şekil 3).



Şekil 3. Çalışma alanındaki mevcut heyelanların genel görünümüne örnekler

Toplam 2644.5 km²'den oluşan, Yukarı Karasu Havzası'nın Aziziye-Aşkale ilçe idari sınırlarına karşılık gelen çalışma alanında tespit edilen 334 adet heyelan toplam alan içerisinde 91.6 km²'lik alansal bir büyüklüğe sahiptir. Bu rakam toplam alanın %3.46'sına karşılık gelmektedir. Çalışma alanında heyelanlar boyutları itibarı ile 1/25.000 ölçekli haritada alansal olarak gösterilebilecek niteliktedirler. Bu nedenle heyelanların alansal dağılımının gösteriminde 25x25 m mekânsal çözünürlük tercih edilmiştir. Bu durumda çalışma alanında toplam hücre sayısı 4.231.349 ve heyelanlı alanların toplam hücre sayısı ise 146.635 olarak belirlenmiştir.

Arazi çalışmaları süresince hem heyelan envanteri oluşturulmuş hem de heyelanların boyutlarına (uzunluk, genişlik, derinlik) ilişkin veriler kayıt altına alınmıştır. Bu veriler sayesinde envanter haritası ile birlikte heyelanların boyutsal dağılımları da grafiklerle sunulmuştur (Şekil 4). Çalışma alanındaki heyelanların boyutları genel olarak değerlendirildiğinde heyelanların yaklaşık %75'i 0-1000 m uzunluk, 0-600 m genişlik değerlerine sahip olmakta ve yine mevcut heyelanların yaklaşık %85'inin derinlik değerleri ise 0-60m arasında değişmektedir.



Şekil 4. Heyelan envanter haritası ve heyelanların boyutları

3.2. Kullanılan Parametreler

3.2.1. Litoloji

Heyelan oluşumundaki en önemli faktörlerin başında litoloji gelmektedir. Bu değişken heyelan duyarlılık haritalarının hazırlanmasına yönelik çalışmaların hemen hemen tamamında kullanılmıştır. Litolojik birimlerin kaymaya karşı duyarlılığı, bu birimlerin su tutma kapasiteleri ve kayma gerilmelerindeki farklılıklar nedeni ile değişmektedir (Dağ, 2007; Dağ vd., 2021).

Litolojik özellikler değerlendirilirken bir takım araştırmacılar arazi gözlemlerine ve tecrübelerine dayanan nitel değerlendirmeleri dikkate almıştır (Maharaj, 1993; Nagarajan vd., 2000). Bazı araştırmacılar ise çalışma alanında heyelanların hangi litolojik birimler içerisinde dağılım gösterdiğini istatistiksel değerlendirmelerle ortaya koymuş ya da yamaç malzemesinin dayanım özelliklerinden yararlanmıştır (Süzen ve Doğan, 2004; Çellek, 2013; Dağ ve Bulut, 2012; Neuhauser vd., 2012; Kayastha vd., 2013; Romer ve Ferentinou, 2016; Dağ vd., 2021). Mineral ve kayalarda sonradan oluşan fiziksel ve kimyasal değişimlerin neden olduğu bozunma da kaymayı etkileyen önemli bir etken olup bozunmanın derecesine bağlı olarak aynı litolojik birim içerisinde dahi heyelana olan hassasiyetin boyutları değişmektedir (Gökçeoğlu

ve Ercanođlu, 2001). Çalışmada litoloji deđiřkeni formasyon mertebesinde sınıflandırılmış olup toplam 14 alt parametreden oluşan litoloji haritası üretilmiştir. Bu harita ile mevcut heyelanlar akıştırılarak çalışma alanında heyelanların hangi birimler içerisinde dađılım gerekleřtirdiđi tespit edilmiştir (Şekil 5a).

3.2.2. Yükseklik

Bu kavram, deniz seviyesinden itibaren topođrafik yüksekliđi ifade etmektedir. Aslında bu parametrenin heyelan oluşumuna doğrudan etkisini ifade etmek ok gereki olmayabilir. Bazı çalışmalarda topođrafik olarak yüksek kesimlerin heyelan açısından daha duyarlı olduđu belirtilirken bazı arařtırmalarda ise orta ve düşük yükseklik deđerlerinin heyelan oluşumuna elverişli olduđu tespit edilmiştir. Aslında bu farklı yükseklik deđerlerinin heyelan oluşumunda etkili olmaları heyelana neden olan ve ilgili çalışma alanı için daha etkili olacađı düşünölen diđer özelliklerden kaynaklanmaktadır (Dađ, 2007).

Çalışmada Harita Genel Müdürlüđü’nden temin edilen 1/25000 ölekli sayısal topođrafik haritalar kullanılmıştır. Sayısal yükseklik modelinden hareketle raster veri formatında ve 25 m mekânsal özünörlüđe sahip yükseklik haritası üretilmiştir. Eđimi, baki ve yama eğrisellik haritaları da Sayısal Yükseklik Modelinden (SYM) türetilmiştir.

Yükseklik haritası oluşturulurken SYM haritası 14 farklı sınıfta 100’er metrelik aralıklarla yeniden sınıflandırılmıştır. Çalışma alanı 1507 m ile 3112 m arasında deđişen yükseklik deđerlerinden oluşmaktadır (Şekil 5b).

3.2.3. Yama Eğimi

Yamaların sahip oldukları eđim deđerleri litolojiden sonra duyarlılık analizlerinde en fazla deđerlendirilen parametrelerin başında gelmektedir (Dađ vd. 2011). Arařtırmacılar arasında yama eđiminin heyelan oluşumunda doğrudan etkili olduđu yönünde bir fikir ortaklıđı söz konusudur. Eđim deđerindeki artışa bađlı olarak yamaların heyelan açısından daha hassas olacađına yönelik genel bir göröř hakimdir (Ayalew vd., 2004; Lee, 2005; Fell vd., 2008). Bununla birlikte Temesgen vd. (2001) ile Ayalew ve Yamagishi (2005) gibi bir takım arařtırmacıların yapmış oldukları çalışmalarda 20°’nin altında düşük eđim deđerindeki yamalarda da heyelanların oluştuđu belirtilmektedir (Dađ ve Bulut, 2012).

Bu çalışmada inceleme alanının eđim haritası ArcGIS 10.2 yazılımı kullanılarak SYM haritasından hareketle üretilmiştir. Çalışmada eđim haritası 5’er derece aralıklarla 11 kategoride sınıflandırılmıştır (Şekil 5c). Üretilen eđim haritasına göre çalışma alanında eđim deđerleri 3.46° ile 52° arasında deđişmektedir.

3.2.4. Yama Eğim Yönü (Baki)

Yama eğim yönü arařtırmacılar tarafından duyarlılık çalışmalarında kullanılan başlıca deđerlendirme parametrelerinden biridir. Buna rađmen yama eğim yönünün heyelan oluşumunda hangi öneme sahip olduđuna dair fikir birliđi söz konusu deđildir. Ancak heyelanların belli yönelimdeki yamalarda yoğunlaşması birok arařtırmacı tarafından istatistiksel olarak deđerlendirilmiştir (Dađ, 2007).

Yamalarda yađış nedeniyle heyelanların belli bir yönelimde daha fazla oluştuđu ve bu durumun alanın morfolojik yapısından ileri geldiđi düşünölmektedir (Aydođan, 2019). Yađışın yoğun olduđu yamalar eğim, geirimlilik özelliđi, bitki örtüsünün türü ve zemin türü gibi faktörlerin etkisi ile süzölme kapasitesine de bađlı olarak doygun hale gelebilmektedir. Bu durum da yamaların heyelan oluşumunu etkilemektedir (Gökeođlu ve Ercanođlu, 2001). Benzer şekilde belli yönelimlere sahip yamalarda heyelanların daha sık gözlenmesinde sahanın morfolojik yapısı, bölgenin genel yađış yönü, güneş ışığını daha fazla alması gibi meteorolojik olaylar da etkili olmaktadır (Dađ ve Bulut, 2012).

Çalışma kapsamında SYM’den hareketle yama eğim yönü haritası üretilmiştir. Eğim yönü haritası düz yamaların yanı sıra ara ve ana yönler de dikkate alınarak toplamda 9 sınıftan oluşacak şekilde yeniden sınıflandırılmıştır (Şekil 5d).

3.2.5. Yama Eğriselliđi

Yamalarda farklı topođrafik şekillerin bir ürünü olarak iç bükey, dış bükey ve düz alanlardan oluşan arazi şekilleri yüzey sularının akışını kontrol etmekte ve heyelan oluşumunda etkin rol oynamaktadır. Eğrisellik parametrelerinde negatif deđerler iç bükey, pozitif deđerler dış bükey, sıfıra yakın deđerler ise düz alanları temsil etmektedir (Tekin ve an, 2019). Bu konuda, dışa eğimli yamaların iç bükey yamalara nazaran heyelan açısından daha hassas olduđu düşünölmekle birlikte farklı göröřlerin ortaya konulduđu çalışmalarda da mevcuttur (Aydođan, 2019).

Yama eğriselliđi haritaları da diđer topođrafik parametreler gibi SYM’den üretilmektedir. Konu ile ilgili çalışmalarda eğriselliđin eđim deđerleri ile iliřkili olarak bu deđerlerdeki göreceli farklılıklara bađlı olduđu ifade edilmektedir (Erener ve Düzgün, 2010).

Çalışmada yamaç eğriselliđi haritası olarak dış bükey alanlar pozitif, iç bükey alanlar negatif ve düz alanlar ise sıfır değeri ile temsil edilerek 3 sınıfta üretilmiştir. Eğrisellik haritasında yamaç eğriselliđi değeri -3.5 ile 4.79 arasında deđişim göstermiştir (Şekil 5e).

3.2.6. Arazi Kullanımı

Genel olarak ormanlık alanlar gibi bitki örtüsünün yoğun olduđu yerler, tarımsal alanlar ve yerleşim alanları ile seyrek bitki örtüsüne sahip alanlara oranla, heyelan olaylarından daha az etkilenmektedir. Özellikle yağışın etkisi ile zemine sızma ve zeminin doygun hale gelmesinde bitkinin kök ve yapraklarının önleyici bir role sahip olduđu bilinmektedir. Bununla birlikte bitki köklerinin zemini güçlendirdiđi ve kayma dayanımında artmaya sebebiyet verdiđi ifade edilmektedir. Bütün bu olumlu görüşlerin yanı sıra bitki kök ve gövdelerinin gelişimi ile birlikte zemin yüzeyinin geçirgenliğinin artması ve yüzey sularının zemine geçişinin kolaylaşması nedeniyle yamaç dengesini bozduđu yönünde görüşler de söz konusudur (Aydođan, 2019).

Çalışmada Tarım ve Orman Bakanlığı tarafından üretilmiş olan arazi kullanımı haritasından yararlanılmıştır. Bu haritadan çalışma alanı sınırları dikkate alınarak arazi kullanım haritası elde edilmiştir. Bu haritanın üretilmesinde, sınıflamalarda duyarlılık bakımından benzer özelliđe sahip olacađı düşünölen kullanım alanları birleştirilerek genel olarak dört sınıf oluşturulmuştur. Buna göre çalışma alanında arazi kullanımı, çıplak kayalık alanlar, karışık tarım alanları, şehir yapısı ve endüstriyel alanlar ile mera ve çayırılık alanlardan oluşmaktadır (Şekil 5f).

3.2.7. Ana Faya Yakınlık

Ölkemiz bir deprem ülkesi olmakla birlikte afet olayları açısından da en fazla can ve mal kaybının yaşandıđı afetler içerisinde depremler birinci sırada yer almaktadır. Özellikle sismik aktiviteler yönünden önemli olan bölgelerde fay türü yapısal unsurlara olan mesafe heyelanların oluşumu açısından önemlidir. Faylara yakın alanlarda oluşacak sismik aktiviteler nedeniyle zemin yapısı bozularak dayanımı azalmaktadır. Bu alanlarda meydana gelebilecek sismik hareketler heyelanlar açısından tetikleyici bir unsur olmaktadır. Bundan dolayı faylara yakın olan alanların heyelana olan hassasiyetinin yüksek olacađı, bu tür yapısal unsurlardan uzaklaştıkça hassasiyetin azalacađı genel anlamda kabul görmektedir. Fayların etki alanının büyüklüđu göz önünde bulundurulduğunda ana faya yakınlık parametresinin değerlendirildiđi çalışmalarda sınıf aralıkları geniş tutulmaktadır (Aydođan, 2019).

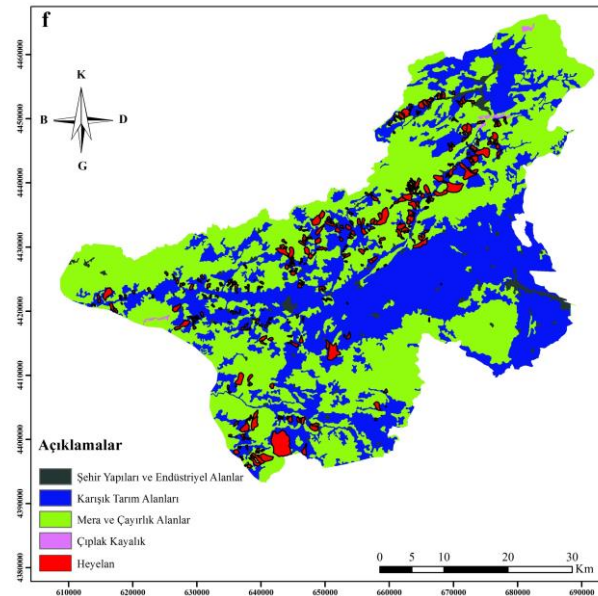
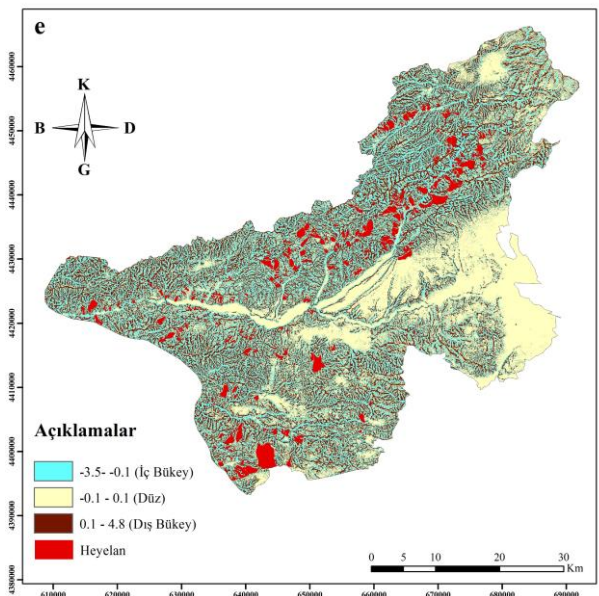
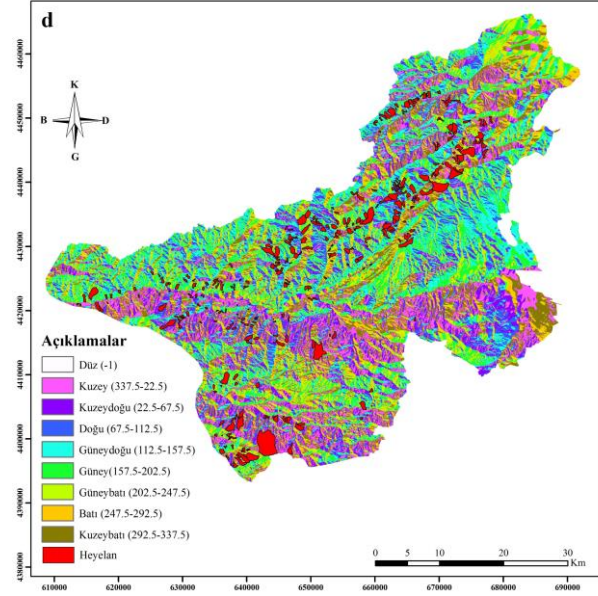
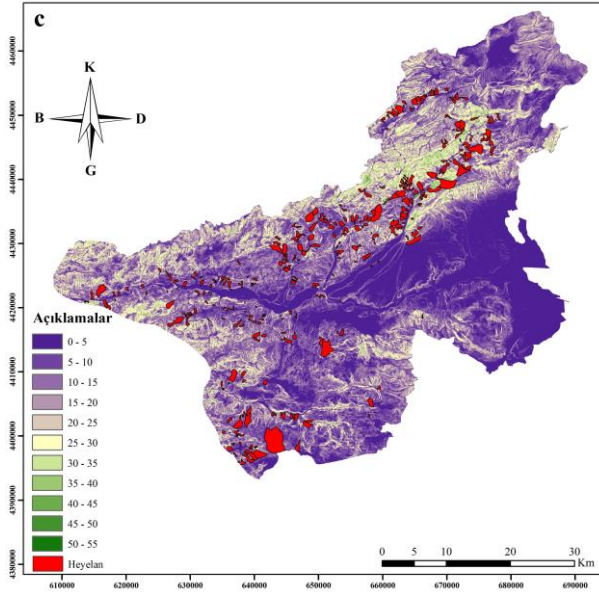
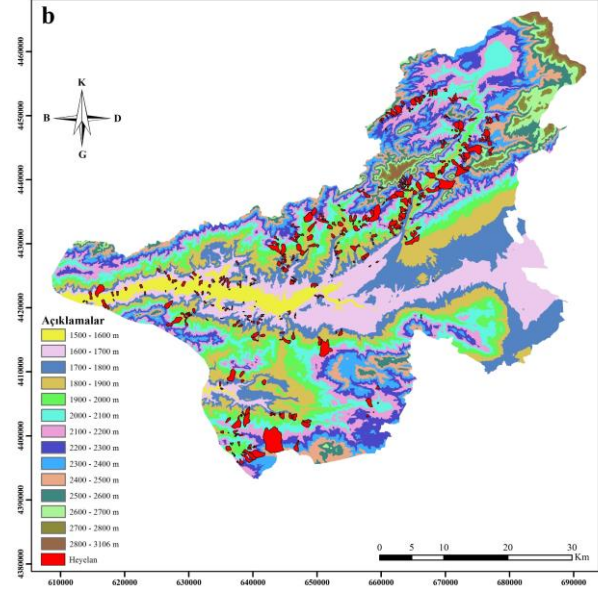
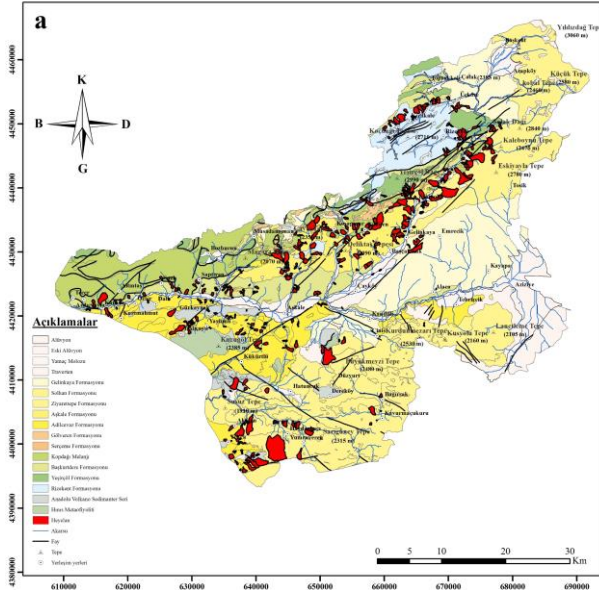
Alpin dađ oluşumu ve neotektonik dönemler olmak üzere jeolojik zaman olarak iki farklı dönemde kuzey kuzeybatı – güney güneydođu (KKB-GGD) hatlarında sıkışma rejimine maruz kalan çalışma alanında bindirme fayları ve nap türü yapısal unsurlarla birlikte çok sayıda aktif ve pasif fay mevcuttur. Tabaka ve özellikle fayların çoğunluđu KD-GB doğrultuludur. Bu durum heyelan envanter haritasında heyelanların bu doğrultularda varlığı ile ilişkilendirildiğinde, heyelan oluşumunda fayların etkili olduđu görüşünü desteklemektedir. Bundan dolayı ana faya yakınlık parametresi duyarlılık analizlerinde özellikle tercih edilmiştir.

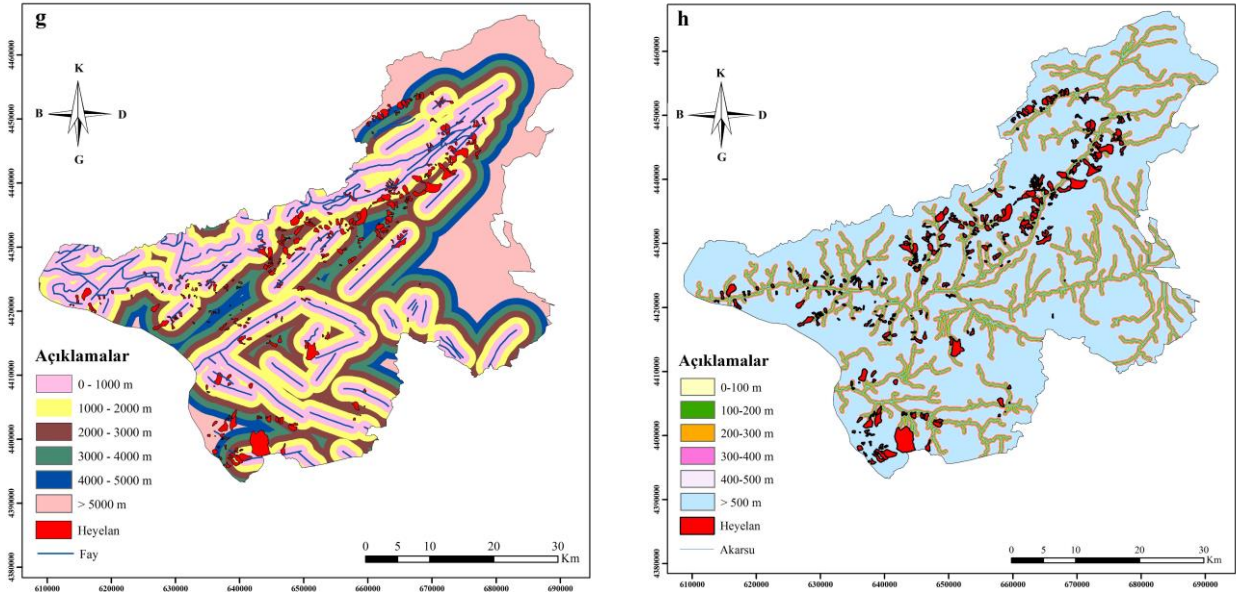
Çalışma kapsamında, Maden Tetkik ve Arama Genel Müdürlüđu (MTA) tarafından oluşturulan 1/100.000 ölçekli topoğrafik haritalardan yararlanılarak fay haritası oluşturulmuştur. Duyarlılık analizlerinde kullanılmak üzere etki alanı dikkate alınarak 1000'er metre aralıklı altı farklı sınıfta ana faya yakınlık haritası üretilmiştir. Bu harita üzerine mevcut heyelanlar bindirilerek heyelanların hangi aralıklarda daha fazla gerçekleştiđi araştırılmıştır (Şekil 5g).

3.2.8. Akarsuya Yakınlık

Heyelan duyarlılık haritalarının hazırlanmasına yönelik birçok çalışmada yamaçların drenaj ađına olan mesafeleri yamaçların dengeleri açısından önemli olarak değerlendirilmiştir. Birçok araştırmacı tarafından akarsuya olan yakınlık heyelan olasılığı açısından bir parametre olarak kullanılmıştır. Akarsuların, yamaç topuklarını erozyona uğratmaları ya da akarsu seviyesinin altında yamaç malzemesinin suya doygun hale gelmesi bu deđişkenin heyelan oluşumu açısından değerlendirilmesinin nedeni olarak gösterilmektedir (Dađ ve Bulut, 2012).

Yukarı Karasu Havzası genelinde yoğun drenaj ađı varlığı nedeni ile bu çalışmada akarsuya yakınlık parametresi duyarlılık analizlerinde kullanılmıştır. ArcGIS 10.2 yazılımı yardımıyla akarsulara 100'er metre aralıklı altı farklı tampon bölgeler oluşturulmuştur. Akarsuya yakınlığın heyelanlara olan etkisini belirlemek için akarsuya yakınlık haritası üretilmiş ve akarsuların heyelanlarla ilişkileri irdelenmiştir (Şekil 5h).





Şekil 5. Parametre haritaları ve heyelan alanları

3.3. Yöntem

Çalışmada heyelan analizlerinin gerçekleştirilmesi ve duyarlılık haritalarının üretilmesinde istatistiksel yöntemler içerisinde yer alan Frekans oranı yöntemi (FO) ve Bayes olasılık modelinden (BO) yararlanılmıştır. Her iki yöntem de heyelan analizlerine yönelik çalışmalarda araştırmacılar tarafından yaygın olarak kullanılan istatistiksel yöntemlerdir.

3.3.1. Frekans Oranı Yöntemi

Bu yöntem genel olarak belirli bir doğa olayının meydana gelmesinin, aynı olayın meydana gelmemesine oranının olasılığını ifade etmektedir. Frekans oranı (FO) yönteminin heyelan duyarlılığına yönelik çalışmalara ilişkin temel prensibi “heyelanlar geçmişte hangi koşullar altında oluştu ise gelecekte de benzer koşullar altında oluşacaktır” varsayımını esas almaktadır. Uygulama açısından da kolay olan bu yöntem konuya yönelik çalışmalarda yaygın bir şekilde kullanılmaktadır (Akgün vd., 2008; Pradhan ve Lee, 2010; Baştuđ, 2018; Kılıçođlu, 2020).

Bu yöntem parametre sınıfları ile ilgili olarak hesaplanan yoğunluk analizlerini dikkate almaktadır (Lee ve Talib, 2005). Modelle ilgili çalışmalarda Cođrafi Bilgi Sistemleri yazılımları kullanılarak envanter haritası ile ilişkilendirilen parametrelerin yoğunluk analizleri gerçekleştirilmektedir (Erener ve Düzgün 2010). Daha sonra bu ilişki ve yoğunluk analizi temelinde frekans oranı deđerleri ařađıdaki eşitlikten hareketle belirlenmektedir.

$$FO = \left(\frac{HPix}{\sum B} \right) / \left(\frac{Pix}{\sum A} \right) = \%B / \%A \quad (1)$$

Bu eşitlikte;

$HPix$; Parametre alt sınıfı heyelanlı hücre sayısı

$\sum B$; Çalışma alanı toplam heyelanlı hücre sayısı

Pix ; Parametre alt sınıfı hücre sayısı

$\sum A$; Çalışma alanı toplam hücre sayısı

Eşitlikten elde edilen frekans oranı deđerinin 1’den çok veya az bir deđere sahip olması, çalışma alanında heyelan oluşumunda etkin olduđu düşünölen parametrelerin heyelan oluşumuna etkisini tanımlamak açısından önemlidir. Frekans oranı 1’den ne kadar büyük bir rakamsal deđere sahip olursa, ilgili parametre alt sınıfı ile heyelan oluşumu arasındaki ilişki o kadar fazla, 1’den ne kadar küçük bir deđere sahip olursa, ilişki o kadar düşük olacaktır (Lee ve Talib, 2005). Çalışmada elde edilen frekans oranı deđerleri Tablo 1’de verilmiştir.

3.3.2. Bayes Olasılık Modeli

Bayes olasılık modeli, bir olayla ilgili daha önceki olasılık beklentilerini, olayın gerçekleşmesi durumunda elde edilen yeni bilgiler dâhilinde güncelleyerek daha sonraki bir zamanda benzer bir olayın gerçekleşme olasılığını elde etmek için kullanılan bir modeldir (Akıncı vd., 2017). Bu modelde parametrelerin kendileri rastlantı değişkeni olup olasılık dağılımına uymaktadır. Heyelanları etkileyen faktörler değiştiğinden dolayı faktörlerin altındaki sınıflara ait bilgilerde değişmektedir. Oysa heyelan envanterinde heyelanları meydana getiren şartlar heyelan olmadığı sürece ilgili alan için sabittir.

Bayes olasılık modelinin daha açık olarak hesaplanabilmesi için “Kanıt Ağırlıkları (Weight of Evidence, WoE)” modeli kullanılmaktadır (Akıncı vd., 2017; Kılıçoğlu, 2020). Bu model Bayes yaklaşımının içinde koşullu ve koşulsuz olasılıkların yeterli veriler kullanılarak uygulandığı bir yöntemdir. Model sayesinde çalışılan alanda gelecekte bir heyelanın meydana gelebilmesini öngören tahminlere pozitif ağırlıklar, heyelan oluşmamasını öngören tahminlere de negatif ağırlıklar atanmaktadır (Akıncı vd., 2017). WoE modeli van Westen vd. (2003) ve Regmi vd. (2010) tarafından matematiksel bir eşitlikle ifade edilmiştir. Ağırlıkların belirlenmesinde aşağıdaki eşitliklerden yararlanılmaktadır.

$$W^+ = \frac{\frac{A_1}{A_3}}{\frac{A_1+A_2}{A_3+A_4}} \quad W^- = \frac{\frac{A_2}{A_4}}{\frac{A_1+A_2}{A_3+A_4}} \quad C = W^+ - W^- \quad (2)$$

Bu eşitliklerde;

- A_1 ; Parametre alt sınıfındaki heyelanlı hücre sayısı
- A_2 ; Parametre alt sınıfı haricindeki heyelanlı hücre sayısı
- A_3 ; Parametre alt sınıfındaki heyelansız hücre sayısı
- A_4 ; Parametre alt sınıfı haricindeki heyelansız hücre sayısı
- W^+ ; Pozitif ağırlık
- W^- ; Negatif ağırlık
- C ; Ağırlık kontrastını ifade etmektedir.

Pozitif ağırlık (W^+), heyelanların oluşumu açısından faktörün varlığının önemini belirtmek için kullanılmaktadır. Bu değer pozitif (+) ise ilgili faktörün varlığı heyelan oluşumu için elverişli, negatif (-) ise elverişli değildir. Negatif ağırlık (W^-) ise heyelanların oluşumu açısından etkenin yokluğunun heyelan oluşumu açısından önemini değerlendirmek için kullanılmaktadır. Bu değer pozitif (+) ise ilgili faktörün yokluğu heyelan oluşumu için elverişli, negatif (-) ise elverişli değildir. Pozitif ve negatif ağırlıklar arasındaki fark “ağırlık kontrastı (C)” değeri ise tahmin değişkeninin heyelan ile mekânsal ilişkisini yansıtmaktadır. Bu değer pozitif olması değişkenin heyelan ile konumsal bir ilişkisini, negatif olması ise değişkenin heyelan ile konumsal bir ilişkisinin olmadığını ifade etmektedir. Ağırlık kontrastı değerinin sıfıra eşit olması durumu ise heyelana neden olan faktöre ait alt kategorinin analiz için önemli (anlamli) olmadığını göstermektedir (van Westen vd., 2003; Neuhauser ve Terhorst, 2007; Corsini vd., 2009, Akıncı vd., 2015; Akıncı vd., 2017; Kılıçoğlu, 2020). Çalışmada duyarlılık hesaplamalarında kullanılan parametrelere ait Bayes olasılık modeline ilişkin ağırlık değerleri Tablo 1’ de verilmiştir.

3.4. Heyelan Duyarlılık Haritalarının Üretilmesi

Çalışmada veri analizlerinin gerçekleştirilmesinde ve heyelan duyarlılık haritalarının üretilmesinde CBS ortamında ArcGIS 10.2 yazılımından yararlanılmıştır. Öncelikle eşyüksele haritaları birleştirilerek Yukarı Karasu Havzası’nın çalışma alanı olarak seçilen kuzeydoğu bölümünün sınırları oluşturulmuştur. Bu işlemde Yukarı Karasu Havza sınırı ile Aziziye ve Aşkale ilçelerinin idari sınırlarının kesişim sınırı dikkate alınmıştır. Bu şekilde çalışma alanında tek bir hücre boyutu 25x25 m’den oluşan 4.231.349 adet hücre elde edilmiştir.

Çalışmada ayrıntıları daha önceki bölümlerde belirtilen bir takım özellikler dikkate alınarak bazı jeolojik, topoğrafik ve çevresel parametrelerin heyelan oluşumunda etkili olacağı düşünülmüş ve ilgili bu parametreler heyelan duyarlılık haritalarının üretiminde kullanılmıştır. Öncelikle her bir parametreye ait parametre haritaları üretilmiştir (Şekil 5). Parametre haritaları daha sonra sınıflandırılarak alt kategorilere ayrılmış ve bu sayede parametre alt sınıflarına ait toplam alanlarla heyelanlı alanlar ayrı ayrı belirlenmiştir. Her bir parametre haritası envanter haritası ile karşılaştırılarak önceki heyelanların parametre alt sınıflarından hangilerine karşılık geldiği tespit edilmiştir (Tablo 1). Bu sayede aynı zamanda parametre alt sınıflarının da heyelan oluşumu açısından hassasiyetleri hakkında fikir sahibi olunmuştur.

Tablo 1. Parametre alt sınıfları ve model değerleri

| | 4231349 | 146635 | | | | | | | | | | | |
|-----------------|-------------------------|--------------|-----------------|-------|-------------|-------------|----------------|----------------|----------------|----------------|----------------|----------------|--------------|
| | Parametre Alt Sınıfları | Toplam Hücre | Heyelanlı Hücre | %A | %B | FO | A ₁ | A ₂ | A ₃ | A ₄ | W ⁺ | W ⁻ | C |
| LİTOLOJİ | Alv. Ymç. Mlz. | 593235 | 14018 | 14.02 | 9.56 | 0.68 | 14018 | 132617 | 593235 | 3638114 | -0.38 | 0.05 | -0.43 |
| | Adilcevaz F. | 388195 | 15386 | 9.17 | 10.49 | 1.14 | 15386 | 131249 | 388195 | 3843154 | 0.13 | -0.01 | 0.15 |
| | Aşkale F. | 239922 | 32127 | 5.67 | 21.91 | 3.86 | 32127 | 114508 | 239922 | 3991427 | 1.35 | -0.19 | 1.54 |
| | Anadolu Vol. S. | 103664 | 5908 | 2.45 | 4.03 | 1.64 | 5908 | 140727 | 103664 | 4127685 | 0.50 | -0.02 | 0.51 |
| | Başkurdere F. | 259310 | 9960 | 6.13 | 6.79 | 1.11 | 9960 | 136675 | 259310 | 3972039 | 0.10 | -0.01 | 0.11 |
| | Gelinkaya F. | 615764 | 6207 | 14.55 | 4.23 | 0.29 | 6207 | 140428 | 615764 | 3615585 | -1.23 | 0.11 | -1.35 |
| | Gölveren F. | 15113 | 496 | 0.36 | 0.34 | 0.95 | 496 | 146139 | 15113 | 4216236 | -0.05 | 0.00 | -0.05 |
| | Hınıs Metaofiyolit | 60037 | 349 | 1.42 | 0.24 | 0.17 | 349 | 146286 | 60037 | 4171312 | -1.79 | 0.01 | -1.80 |
| | Rizekent F. | 194690 | 10486 | 4.60 | 7.15 | 1.55 | 10486 | 136149 | 194690 | 4036659 | 0.44 | -0.03 | 0.47 |
| | Kopdağı Mlnj F. | 366502 | 12020 | 8.66 | 8.20 | 0.95 | 12020 | 134615 | 366502 | 3864847 | -0.06 | 0.01 | -0.06 |
| | Serçeme F. | 3985 | 9 | 0.09 | 0.01 | 0.07 | 9 | 146626 | 3985 | 4227364 | -2.73 | 0.00 | -2.73 |
| | Solhan F. | 887130 | 30697 | 20.97 | 20.93 | 1.00 | 30697 | 115938 | 887130 | 3344219 | 0.00 | 0.00 | 0.00 |
| | Yeşircöl F. | 117655 | 1917 | 2.78 | 1.31 | 0.47 | 1917 | 144718 | 117655 | 4113694 | -0.75 | 0.02 | -0.77 |
| | Ziyrettepe F. | 386147 | 7055 | 9.13 | 4.81 | 0.53 | 7055 | 139580 | 386147 | 3845202 | -0.64 | 0.05 | -0.69 |
| YÜKSEKLİK (m) | 1500-1600 | 26767 | 725 | 0.63 | 0.49 | 0.78 | 725 | 145910 | 26767 | 4204582 | -0.25 | 0.00 | -0.25 |
| | 1600-1700 | 154437 | 4309 | 3.65 | 2.94 | 0.81 | 4309 | 142326 | 154437 | 4076912 | -0.22 | 0.01 | -0.22 |
| | 1700-1800 | 612739 | 7519 | 14.48 | 5.13 | 0.35 | 7519 | 139116 | 612739 | 3618610 | -1.04 | 0.10 | -1.14 |
| | 1800-1900 | 616400 | 13398 | 14.57 | 9.14 | 0.63 | 13398 | 133237 | 616400 | 3614949 | -0.47 | 0.06 | -0.53 |
| | 1900-2000 | 423523 | 24500 | 10.01 | 16.71 | 1.67 | 24500 | 122135 | 423523 | 3807826 | 0.51 | -0.08 | 0.59 |
| | 2000-2100 | 400826 | 20182 | 9.47 | 13.76 | 1.45 | 20182 | 126453 | 400826 | 3830523 | 0.37 | -0.05 | 0.42 |
| | 2100-2200 | 452036 | 23078 | 10.68 | 15.74 | 1.47 | 23078 | 123557 | 452036 | 3779313 | 0.39 | -0.06 | 0.45 |
| | 2200-2300 | 454484 | 23317 | 10.74 | 15.90 | 1.48 | 23317 | 123318 | 454484 | 3776865 | 0.39 | -0.06 | 0.45 |
| | 2300-2400 | 393774 | 15914 | 9.31 | 10.85 | 1.17 | 15914 | 130721 | 393774 | 3837575 | 0.15 | -0.02 | 0.17 |
| | 2400-2500 | 278406 | 10282 | 6.58 | 7.01 | 1.07 | 10282 | 136353 | 278406 | 3952943 | 0.06 | 0.00 | 0.07 |
| | 2500-2600 | 181332 | 2631 | 4.29 | 1.79 | 0.42 | 2631 | 144004 | 181332 | 4050017 | -0.87 | 0.03 | -0.90 |
| | 2600-2700 | 107337 | 613 | 2.54 | 0.42 | 0.16 | 613 | 146022 | 107337 | 4124012 | -1.80 | 0.02 | -1.82 |
| | 2700-2800 | 76638 | 167 | 1.81 | 0.11 | 0.06 | 167 | 146468 | 76638 | 4154711 | -2.77 | 0.02 | -2.78 |
| >2800 | 52650 | 0 | 1.24 | 0.00 | 0.00 | 0 | 146635 | 52650 | 4178699 | 0 | 0.01 | 0 | |
| YAMAÇ EĞİMİ (°) | 0-5 | 1041207 | 9753 | 24.61 | 6.65 | 0.27 | 9753 | 136882 | 1041207 | 3190142 | -1.31 | 0.21 | -1.52 |
| | 5-10 | 865523 | 42560 | 20.46 | 29.02 | 1.42 | 42560 | 104075 | 865523 | 3365826 | 0.35 | -0.11 | 0.46 |
| | 10-15 | 868396 | 45747 | 20.52 | 31.20 | 1.52 | 45747 | 100888 | 868396 | 3362953 | 0.42 | -0.14 | 0.56 |
| | 15-20 | 656719 | 26500 | 15.52 | 18.07 | 1.16 | 26500 | 120135 | 656719 | 3574630 | 0.15 | -0.03 | 0.18 |
| | 20-25 | 436411 | 12789 | 10.31 | 8.72 | 0.85 | 12789 | 133846 | 436411 | 3794938 | -0.17 | 0.02 | -0.19 |
| | 25-30 | 241607 | 5588 | 5.71 | 3.81 | 0.67 | 5588 | 141047 | 241607 | 3989742 | -0.40 | 0.02 | -0.42 |
| | 30-35 | 97670 | 2747 | 2.31 | 1.87 | 0.81 | 2747 | 143888 | 97670 | 4133679 | -0.21 | 0.00 | -0.21 |
| | 35-40 | 20784 | 749 | 0.49 | 0.51 | 1.04 | 749 | 145886 | 20784 | 4210565 | 0.04 | 0.00 | 0.04 |
| | 40-45 | 2584 | 184 | 0.06 | 0.13 | 2.05 | 184 | 146451 | 2584 | 4228765 | 0.72 | 0.00 | 0.72 |
| | 45-50 | 420 | 18 | 0.01 | 0.01 | 1.24 | 18 | 146617 | 420 | 4230929 | 0.21 | 0.00 | 0.21 |
| | > 50 | 28 | 0 | 0.00 | 0.00 | 0.00 | 0 | 146635 | 28 | 4231321 | 0 | 0.00 | 0 |

Tablo 1'in devamı

| | Parametre Alt Sınıfları | Toplam Hücre | Heyelanlı Hücre | %A | %B | FO | A1 | A2 | A3 | A4 | W+ | W- | C |
|------------------------|-------------------------|--------------|-----------------|-------|-------|-------------|-------|--------|---------|---------|-------|-------|--------------|
| YAMAÇ EĞİM YÖNÜ (BAKI) | Düz | 31 | 0 | 0.00 | 0.00 | 0.00 | 0 | 146635 | 31 | 4231318 | 0 | 0.00 | 0 |
| | Kuzey | 576392 | 24080 | 13.62 | 16.42 | 1.21 | 24080 | 122555 | 576392 | 3654957 | 0.19 | -0.03 | 0.22 |
| | Kuzeydoğu | 421335 | 15373 | 9.96 | 10.48 | 1.05 | 15373 | 131262 | 421335 | 3810014 | 0.05 | -0.01 | 0.06 |
| | Doğu | 452133 | 12800 | 10.69 | 8.73 | 0.82 | 12800 | 133835 | 452133 | 3779216 | -0.20 | 0.02 | -0.22 |
| | Güneydoğu | 631486 | 19011 | 14.92 | 12.96 | 0.87 | 19011 | 127624 | 631486 | 3599863 | -0.14 | 0.02 | -0.16 |
| | Güney | 667201 | 21876 | 15.77 | 14.92 | 0.95 | 21876 | 124759 | 667201 | 3564148 | -0.06 | 0.01 | -0.07 |
| | Güneybatı | 456280 | 15583 | 10.78 | 10.63 | 0.99 | 15583 | 131052 | 456280 | 3775069 | -0.01 | 0.00 | -0.02 |
| | Batı | 463967 | 16125 | 10.96 | 11.00 | 1.00 | 16125 | 130510 | 463967 | 3767382 | 0.00 | 0.00 | 0.00 |
| EĞRİSELLİK | Kuzeybatı | 562524 | 21787 | 13.29 | 14.86 | 1.12 | 21787 | 124848 | 562524 | 3668825 | 0.11 | -0.02 | 0.13 |
| | -3.5 - (-0.1) | 1322245 | 61530 | 31.25 | 41.96 | 1.34 | 61530 | 85105 | 1322245 | 2909104 | 0.29 | -0.17 | 0.46 |
| | -0.1 - 0.1 | 1555710 | 38502 | 36.77 | 26.26 | 0.71 | 38502 | 108133 | 1555710 | 2675639 | -0.34 | 0.15 | -0.49 |
| | 0.1 - 5 | 1353394 | 46603 | 31.98 | 31.78 | 0.99 | 46603 | 100032 | 1353394 | 2877955 | -0.01 | 0.00 | -0.01 |
| ARAZİ KULLANIMI | Şeh. Yap. ve En. | 75382 | 541 | 1.78 | 0.37 | 0.21 | 541 | 146094 | 75382 | 4155967 | -1.57 | 0.01 | -1.59 |
| | Tarım Alanı | 1821702 | 66279 | 43.05 | 45.20 | 1.05 | 66279 | 80356 | 1821702 | 2409647 | 0.05 | -0.04 | 0.09 |
| | Mera-Çayırılık A. | 2325896 | 79815 | 54.97 | 54.43 | 0.99 | 79815 | 66820 | 2325896 | 1905453 | -0.01 | 0.01 | -0.02 |
| | Çıplak Kayalık | 8369 | 0 | 0.20 | 0.00 | 0.00 | 0 | 146635 | 8369 | 4222980 | 0 | 0.00 | 0 |
| ANA FAYA YAKINLIK (m) | 0-1000 | 1329355 | 50395 | 31.42 | 34.37 | 1.09 | 50395 | 96240 | 1329355 | 2901994 | 0.09 | -0.04 | 0.13 |
| | 1000-2000 | 998584 | 43548 | 23.60 | 29.70 | 1.26 | 43548 | 103087 | 998584 | 3232765 | 0.23 | -0.08 | 0.31 |
| | 2000-3000 | 680857 | 34381 | 16.09 | 23.45 | 1.46 | 34381 | 112254 | 680857 | 3550492 | 0.38 | -0.09 | 0.47 |
| | 3000-4000 | 406962 | 16777 | 9.62 | 11.44 | 1.19 | 16777 | 129858 | 406962 | 3824387 | 0.17 | -0.02 | 0.19 |
| | 4000-5000 | 235919 | 1534 | 5.58 | 1.05 | 0.19 | 1534 | 145101 | 235919 | 3995430 | -1.67 | 0.05 | -1.72 |
| | > 5000 | 579672 | 0 | 13.70 | 0.00 | 0.00 | 0 | 146635 | 579672 | 3651677 | 0 | 0.15 | 0 |
| AKARSUYA YAKINLIK (m) | 0-100 | 339305 | 7693 | 8.02 | 5.25 | 0.65 | 7693 | 138942 | 339305 | 3892044 | -0.42 | 0.03 | -0.45 |
| | 100-200 | 322774 | 10492 | 7.63 | 7.16 | 0.94 | 10492 | 136143 | 322774 | 3908575 | -0.06 | 0.01 | -0.07 |
| | 200-300 | 303330 | 11036 | 7.17 | 7.53 | 1.05 | 11036 | 135599 | 303330 | 3928019 | 0.05 | 0.00 | 0.05 |
| | 300-400 | 288026 | 10922 | 6.81 | 7.45 | 1.09 | 10922 | 135713 | 288026 | 3943323 | 0.09 | -0.01 | 0.10 |
| | 400-500 | 280312 | 11310 | 6.62 | 7.71 | 1.16 | 11310 | 135325 | 280312 | 3951037 | 0.15 | -0.01 | 0.16 |
| | > 500 | 2697602 | 95182 | 63.75 | 64.91 | 1.02 | 95182 | 51453 | 2697602 | 1533747 | 0.02 | -0.03 | 0.05 |

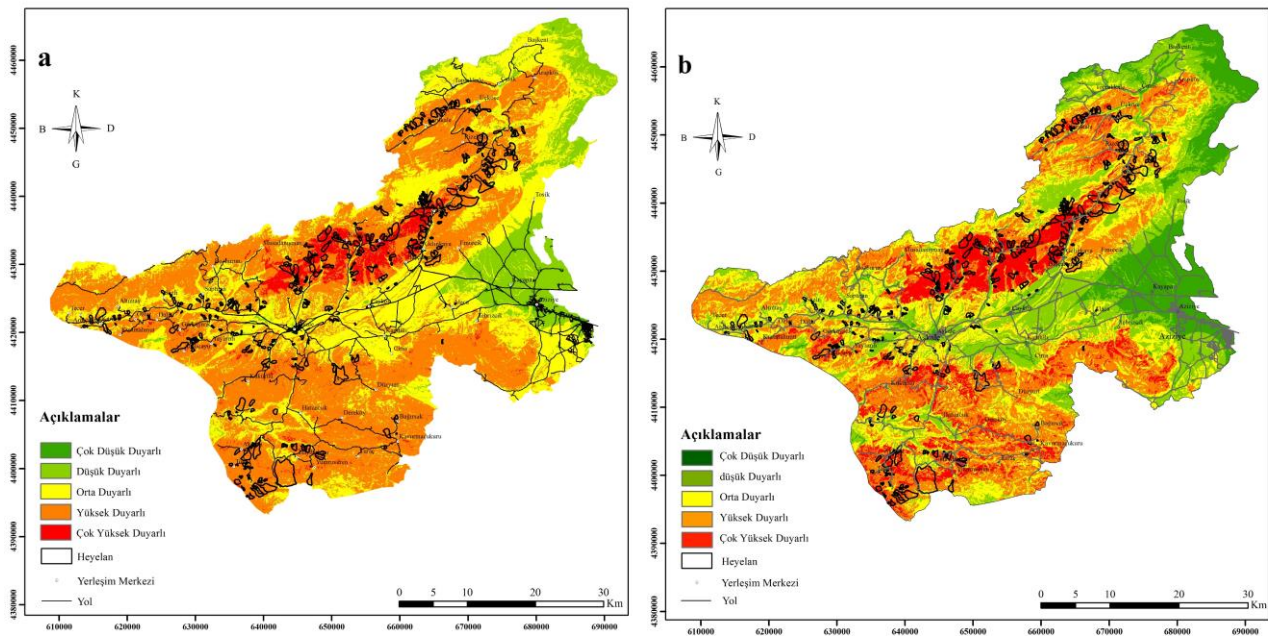
Jeolojik parametrelerden Solhan Formasyonu çalışma alanı içerisindeki dağılımına göre %20.97 oranı ile en fazla yüzeylenen litolojik birimi oluşturmaktadır. %14.57 oranı ile 1800-1900 m arasındaki yükseklik değerine sahip alanlar, çalışma alanındaki en fazla gözlenen yükseklik değerleridir. Çalışma alanındaki yamaçların %24.61'i 0-5° arasında eğim değerine sahip olup %15.77'si güney yönlü yamaçlardan oluşmaktadır. Yamaç eğriselliği gözönünde bulundurulduğunda -0.1 – 0.1 eğrisellik aralığı %36.77 oranı ile en fazla oranda gözlenmektedir. Çalışma alanında arazi kullanımı değerleri dikkate alındığında alanın yarıdan fazlası, %54.97'si mera ve çayırılık alanlardan oluşmaktadır. Fayların etkili olduğu çalışma alanının % 31.42' sinde ana faylara 1000 m den daha yakın alanlar mevcuttur. Akarsuya yakınlık sınıflarında ise "> 500 m" mesafe sınıfı % 63.75 dağılım oranı ile ilk sırada yer almıştır (Tablo 1).

Parametre alt sınıfları göz önünde bulundurularak mevcut heyelanların en fazla hangi sınıfta dağılım gösterdikleri belirlenmiştir. Buna göre; Aşkale Formasyonu %21.91'lik bir oranla heyelanların en fazla dağılım gösterdiği litolojik birimdir. %16.71 oranı ile 1900-2000 m yükseklik değerleri daha önce gelişen heyelanların en fazla gözlendiği yükseklik sınıfıdır. Çalışma alanındaki heyelanlı yamaçların %31.20'si 10-15° arasında eğim değerine sahip olup yine mevcut heyelanların %16.42'si kuzeye bakan yamaçlarda gerçekleşmiştir. -3.5–(-0.1) iç bükey eğrisellik aralığı %41.96 oranı ile var olan heyelanların en yoğun gözlendiği eğrisellik sınıfıdır. 0-1000 m arası ana faya yakınlık sınıfı %34.37 ile mevcut heyelanların en çok dağılım gösterdiği alanları oluşturmaktadır. Çalışma alanında gelişen heyelanların %64.91' i akarsulara 500 m'den daha uzak mesafelerde gelişmiştir. Son olarak mevcut heyelanlar %54.43 ile en fazla mera ve çayırılık alanlarda dağılım göstermiştir (Tablo 1).

Analizlerde, çalışma alanı toplam hücre, toplam heyelanlı hücre sayıları ile her bir parametre alt sınıfına ait toplam ve heyelanlı hücre sayıları belirlenerek frekans oranı değerleri ve ağırlık kontrastı değerleri hesaplanmıştır. Daha sonra elde edilen bu değerler normalleştirilerek duyarlılık haritalarının oluşturulmasında normalleştirilmiş frekans oranı değerleri ve ağırlık kontrastı değerleri kullanılmıştır. Son olarak ArcGIS 10.2 yazılımında Raster Calculator ve Reclassify modülleri kullanılarak çalışma alanına ait duyarlılık haritaları hazırlanmıştır (Şekil 6).

Üretilen duyarlılık haritalarının görsel olarak sunulmasında literatürde genel olarak dört adet veri sınıflandırıcısından bahsedilmektedir. Bunlar eşit aralık, standart sapma, doğal kırılma ve kantil sınıflandırmasıdır (Ayalew vd., 2005; Akgün vd., 2008; Akgün vd., 2012). Bununla birlikte Akıncı (2022) bunlara ilaveten manuel, geometrik aralık ve tanımlı aralık olmak üzere ArcGIS yazılımı ile gerçekleştirilebilen yedi sınıflandırma yönteminden bahsetmektedir.

Bu çalışmada veri dağılımının normale yakın olması nedeni ile eşit aralıklı sınıflandırma tercih edilmiştir. İki farklı yöntemle hazırlanan heyelan duyarlılık haritalarında çok düşük, düşük, orta, yüksek ve çok yüksek duyarlı olmak üzere beş farklı sınıf oluşturulmuştur. Frekans oranı yöntemine göre, çalışma alanının %10.63'ü çok düşük ve düşük duyarlı, %34.35'i orta, %55.02'i ise yüksek ve çok yüksek duyarlı alanlardan oluşmaktadır (Şekil 6a). Bayes olasılık modeli ile üretilen duyarlılık haritasında ise çalışma alanının genelinin %32.13'ü çok düşük ve düşük duyarlı alanlardan oluşurken, %26.66'sının orta, %41.21'lik kısmının ise yüksek ve çok yüksek duyarlı alanlardan oluştuđu belirlenmiştir (Şekil 6b).




Şekil 6. a) Frekans oranı yöntemi, b) Bayes olasılık modeli ile üretilen heyelan duyarlılık haritaları

3.5. Heyelan Duyarlılık Haritalarının Performansının Deđerlendirilmesi

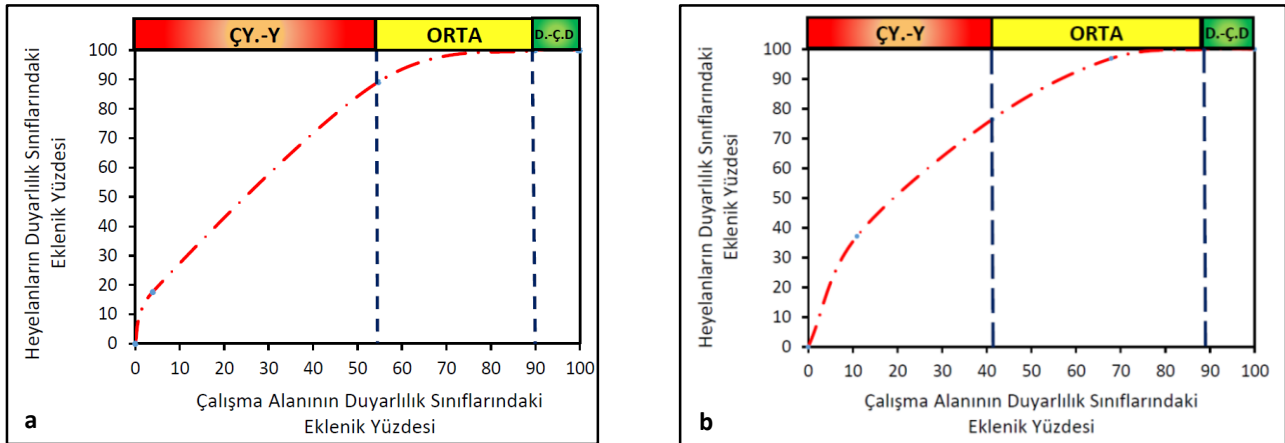
Heyelan duyarlılık analizlerine yönelik yapılan bilimsel çalışmaların temel felsefesi içerisinde "The past and today key to future" ifadesi yer almaktadır. Bu ifade "geçmiş ve bugün gelecek için anahtardır" olarak çevrilebilir. Aslında bu cümle heyelanlar açısından deđerlendirildiğinde geçmişte ve günümüzde heyelanlar hangi koşullar altında gerçekleşti ise gelecekte de benzer koşullar oluştuđu zaman heyelanların gerçekleşebileceğini ifade etmektedir. Tam da bu nedenle bu tür çalışmalarda üretilen heyelan duyarlılık haritalarının doğruluđu ya da performansını gerçek manada deđerlendirmek için o alanda yeni heyelanların oluşmasını beklemek ve yeni oluşan bu heyelanların araştırmacının daha önce üretmiş olduđu duyarlılık haritasında hangi sınıflar içerisinde yer aldığını test etmiş olmak gerekmektedir. Yazarlar bu durumun gerçekçi bir performans analizi olacağını düşünmektedir.

Bununla birlikte konu ile ilgili bilimsel çalışmalarda farklı türde gerçekleştirilen yöntemlerle duyarlılık haritalarının performansları test edilmektedir. Heyelan duyarlılık haritalarının performansları deđerlendirilirken bu deđerlendirmelerin sayısal verilerle destekleniyor olmasının gerekliliđi önemsenmektedir. Bir yöntem olarak hazırlanan duyarlılık haritası ile envanter verileri karşılaştırılarak duyarlılık sınıflarının dağılım yüzdeleri ve bu sınıflara karşılık gelen heyelanların dağılım yüzdeleri hesaplanmaktadır. Bu durumda yüksek ya da çok yüksek duyarlı alanlarda heyelan yüzdelerinin de oransal olarak yüksek deđerlerde olması beklenmektedir (Dađ, 2007).

Bu çalışmada duyarlılık haritalarının performansının değerlendirilmesinde, önce kontrol verileri olarak değerlendirilen mevcut heyelanların, üretilen duyarlılık haritalarındaki dağılımları dikkate alınmıştır. Bunun için envanter haritasından kontrol verisi olarak rastgele ayrılan %20'si duyarlılık haritaları ile karşılaştırılarak hangi sınıflar içerisinde yer aldığı grafik olarak belirlenmiştir (Şekil 7). Ayrıca her iki duyarlılık haritasının performansı başarı-tahmin eğrileri hazırlanarak ta test edilmiştir (Şekil 8). Başarı-tahmin eğrilerine göre Frekans oranı yönteminde çalışma alanının %55.02'si yüksek ve çok yüksek sınıf aralıklarında, heyelanların ise %89.1'i aynı sınıf aralıklarında yer almıştır. Bayes olasılık modeli ile üretilen duyarlılık haritasında ise çalışma alanının %41.21'i, heyelanların ise %76.45'i yüksek ve çok yüksek duyarlı sınıflarda tespit edilmiştir (Şekil 8).



Şekil 7. Duyarlılık haritalarının performans grafiği



Şekil 8. Duyarlılık haritalarının Frekans oranı yöntemi (a) ve Bayes olasılık modeline (b) göre başarı-tahmin eğrileri

4. Sonuç ve Öneriler

Çalışmada heyelan duyarlılık analizlerinde hem frekans oranı yöntemi hem de Bayes olasılık modelinden yararlanılmıştır. Her iki modelde gerçekleştirilen analizler neticesinde jips ve kil gibi su ile etkileştiği zaman kayma açısından potansiyel alanları oluşturan birimleri içeren Aşkale Formasyonu, 40-45° arasındaki eğim değerine sahip yamaçlar ve 0-1000 m arası ana faya yakın alanlar heyelan oluşumu bakımından hassas alanlar olarak belirlenmiştir.

Duyarlılık haritalarında eşit aralıklı sınıflama uygulanarak çok düşük duyarlıdan çok yüksek duyarlıya kadar değişen beş farklı sınıf oluşturulmuştur. Frekans oranı yöntemi ile üretilen duyarlılık haritasında çok düşük duyarlı alanlar %0,47, düşük duyarlı alanlar ise %10,16'lık bir alansal yayılıma sahiptir. Bununla beraber çalışma alanının %34,35'i orta, %50,75'si yüksek ve %4,27'si ise çok yüksek duyarlı alan olarak belirlenmiştir. Bayes olasılık modeli ile üretilen duyarlılık haritasında ise çalışma alanının %11,24'ü çok düşük, %20,89'u düşük, %26,66'sı orta, %30,27'si yüksek ve %10,94'ü ise çok yüksek duyarlı olarak tespit edilmiştir.

Son olarak üretilen haritaların performans analizi gerçekleştirilmiştir. Frekans oranı yöntemi ile üretilen duyarlılık haritasında kontrol amaçlı kullanılan mevcut heyelanların %89,1'lik kısmı, Bayes olasılık modeli ile üretilen duyarlılık haritasında ise mevcut heyelanların %76,45'lik kısmı yüksek ve çok yüksek duyarlı sınıflarda yer almaktadır.

Bu durum hem Frekans oranı yöntemi hem de Bayes olasılık modelinin olası tehlike içeren alanlarda, heyelan risklerinin azaltılması kapsamında heyelanların mekânsal dağılımlarını belirlemede kullanılabilir nitelikte olduğunu göstermektedir. Çalışmada üretilen duyarlılık haritaları bölgesel planlama çalışmalarında karar verme süreçlerinde karar vericiler tarafından kullanılabilir doğruluktur.

Teşekkür

Yazarlar bu çalışmayı destekleyen Erzurum Valiliđi İl Afet ve Acil Durum Müdürlüğü'ne (AFAD) teşekkür eder.

Kaynaklar

- Akdeniz, N., Akçören, F., & Timur, E. (1994). *Aşkale-İspir arasının jeolojisi* (Rapor No. 9731). Ankara: MTA Jeoloji Etütleri Dairesi.
- Akıncı, H., Özalp, A.Y., & Kılıçer, S.T. (2015). Cođrafi bilgi sistemleri ve ahp yöntemi kullanılarak planlı alanlarda heyelan duyarlılığının değerlendirilmesi: Artvin Örneđi. *Dođal Afetler ve Çevre Dergisi*, 1(1-2), 40-53.
- Akıncı, H., Dođan, S., & Kılıçođlu, C. (2017). Landslide susceptibility mapping of Canik (Samsun) district using bayesian probability and frequency ratio models. *Selcuk University Journal of Engineering Science and Technology*, 5(3), 283-299.
- Akıncı, H. (2022). Assessment of rainfall-induced landslide susceptibility in Artvin, Turkey using machine learning techniques. *Journal of African Earth Sciences*, 191, 104535. doi: 10.1016/j.jafrearsci.2022.104535.
- Akgun, A., Sezer, E. A., Nefeslioglu, H. A., Cokceoglu, C., & Pradhan, B. (2012). An easy-to use MATLAB program (MamLand) for the assessment of landslide susceptibility using a Mamdani fuzzy algorithm. *Computers & Geosciences*, 38(1), 23-34.
- Akgün, A., Dađ, S., & Bulut, F. (2008). Landslide susceptibility mapping for a landslide-prone area (Findikli, NE of Turkey) by likelihood-frequency ratio and weighted linear combination models. *Environmental Geology*, 54, 1127-1143.
- Akgün, A. (2018). Bulanık uyarlanabilir rezonans teorisi (FuzzyART) yöntemi kullanılarak heyelan duyarlılık analizi: Tonya (Trabzon) Örneđi. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(1), 135-146.
- Aydođan, E. (2019). *Yukarı Karasu Havzasının Aziziye-Aşkale Arasında Kalan Bölümünün Heyelan Duyarlılık Analizi*, (Yüksek Lisans Tezi). Gümüşhane Üniversitesi, Gümüşhane.
- Ayalew, L., Yamagishi, H., & Ugawa, N. (2004). Landslide susceptibility mapping using GIS-based weighted linear combination, the case in Tsugawa area of Agano river, Niigata prefecture, Japan. *Landslides*, 1, 73-81. doi: 10.1007/s10346-003-0006-9.
- Ayalew, L., & Yamagishi, H. (2005). The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan. *Geomorphology*, 65(1-2), 15-31.
- Ayalew, L., Yamagishi, H., Marui, H., & Kanno, T. (2005). Landslide in Sado Island of Japan: Part II. GIS-based susceptibility mapping with comparison of results from two methods and verifications. *Engineering Geology*, 81, 432-445.
- Baştuđ, G. (2018). *Adrasen ve Olimpos (Antalya) bölgelerinin heyelan duyarlılık haritasının hazırlanması* (Yüksek Lisans Tezi). Hacettepe Üniversitesi, Ankara.
- Corsini, A., Cervi, F., & Ronchetti F. (2009). Weight of evidence and artificial neural networks for potential groundwater spring mapping: an application to the Mt. Modino area (Northern Apennines, Italy). *Geomorphology*, 111(1-2), 79-87. doi: 10.1016/j.geomorph.2008.03.015.
- Çellek, S. (2013). *Sinop-Gerze yöresinin heyelan duyarlılık analizi* (Doktora Tezi). Karadeniz Teknik Üniversitesi, Trabzon.
- Dađ, S. (2007). *Çayeli (Rize) ve çevresinin istatistiksel yöntemlerle heyelan duyarlılık analizi* (Doktora Tezi). Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.
- Dađ, S., Bulut, F., Alemdađ, S., & Kaya A. (2011). Heyelan duyarlılık haritalarının üretilmesinde kullanılan yöntem ve parametrelere ilişkin genel bir değerlendirme. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(2), 151-176.
- Dađ, S., & Bulut F. (2012). Cođrafi bilgi sistemleri tabanlı heyelan duyarlılık haritalarının hazırlanmasına bir örnek: Çayeli (Rize, KD Türkiye). *Jeoloji Mühendisliđi Dergisi*, 36(1), 35-62.
- Dađ, S., Akgün, A., Kaya, A., Alemdađ, A., & Bostancı, H. T. (2021). Medium scale earthflow susceptibility modelling by remote sensing and geographical information systems based multivariate statistics approach: an example from Northeastern Turkey. *Environmental Earth Sciences*, 79, 468, doi: 10.1007/s12665-020-09217-7.
- Derin, L., & Ercanođlu M. (2018). Heyelan duyarlılığı, tehlikesi ve riski ile ilgili çalışmalarda Türkiye ve Avrupa Birliđi ülkelerinin karşılaştırılması. *Afet ve Risk Dergisi*, 1(1), 26-38.
- Erener, A., & Düzgün, H. S. B. (2010). Improvement of statistical landslide susceptibility mapping by using spatial and global regression methods in the case of More and Romsdal (Norway). *Landslides*, 7(1), 55-68.

- Fell, R., Corominas, J., Bonnard, C., Cascini, L., Leroi, E., & Savage, W. Z. (2008). Guidelines for landslide susceptibility, hazard and risk zoning for land use planning. *Engineering Geology*, 102(3), 85-98.
- Fidan, S., & Görüm T. (2020). Türkiye’de ölümcül heyelanların dağılım karakteristikleri ve ulusal ölçekte öncelikli alanların belirlenmesi. *Türk Coğrafya Dergisi*, 74, 123-134.
- Gökçe, O., Özden, Ş., & Demir, A. (2008). *Türkiye’de afetlerin mekânsal ve istatistiksel dağılımı afet bilgileri envanteri*, T.C Bayındırlık ve İskân Bakanlığı, Afet İşleri Genel Müdürlüğü, Afet Etüt ve Hasar Tespit Daire Başkanlığı, Afet İşleri Genel Müdürlüğü.
- Gökçeođlu, C., & Ercanođlu, M. (2001). Heyelan duyarlılık haritalarının hazırlanmasında kullanılan parametrelere ilişkin belirsizlikler. *Yerbilimleri*, 22(23), 189-206.
- Haque, U., da Silva, P.F., Devoli, G., Pilz, J., Zhao, B., Khaloua, A., Wilopo, W., Andersen, P., Lu, P., Lee, J., Yamamoto, T., Keellings, D., Wu, J-H., & Glass, G.E. (2019). The human cost of global warming: deadly landslides and their trigger (1995-2014). *Science of The Total Environment*, 682, 673-684.
- Kayastha, P., Dhital, M.R., & De Smedt, F. (2013). Application of the analytical hierarchy process (AHP) for landslide susceptibility mapping: A case study from the Tinau watershed, west Nepal. *Computers & Geosciences*, 52, 398-408.
- Kılıçođlu, C. (2020). Frekans oranı metodu ve bayesyen olasılık modeli kullanılarak Samsun ili Vezirköprü ilçesinin heyelan duyarlılık haritasının üretilmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 20(1), 138-154.
- Kremier, A., & Arnould, M. (2000). World Bank’s Role in Reducing Impacts of Disasters. *Natural Hazards*, 1(1), 37-42.
- Lee, S. (2005). Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data. *International Journal of Remote Sensing*, 26(7), 1477-1491.
- Lee, S., & Talib, J.A. (2005). Probabilistic Landslide Susceptibility and Factor Effect Analysis. *Environmental Geology*, 47, 982-990.
- Maharaj, R. (1993). Landslide processes and landslide susceptibility analysis from an upland watershed: a case study from St. Andrew West Indies Jamaica. *Engineering Geology*, 34(1-2), 53-79.
- Nagarajan, R., Roy, A., Vinod Kumar, R., Mukherjee, A., & Khire, M.V. (2000). Landslide hazard susceptibility mapping based on terrain and climatic factors for tropical monsoon regions. *Bulletin of Engineering Geology and the Environment*, 58, 275-287.
- Neuhauser, B., Damm, B., & Terhorst, B. (2012). GIS-based assessment of landslide susceptibility on the base of the weights-of-evidence model. *Landslides*, 9(4), 511-528.
- Neuhauser, B., & Terhorst B. (2007). Landslide susceptibility assessment using “weights-of-evidence” applied to a study area at the Jurassic escarpment (SW-Germany). *Geomorphology*, 86(1-2), 12-24.
- Pradhan, B., & Lee S. (2010). Delineation of landslide hazard areas on Penang Island-Malaysia: by using frequency ratio-logistic regression, and artificial neural network model. *Environmental Earth Sciences*, 60, 1037-1054.
- Regmi, N.R., Giardino, J.R., & Vitek, J.D. (2010). Modeling susceptibility to landslides using the weight of evidence approach: Western Colorado, USA. *Geomorphology*, 115(1-2), 172-187.
- Romer, C., & Ferentinou, M. (2016). Shallow landslide susceptibility assessment in a semiarid environment—A Quaternary catchment of KwaZulu-Natal, South Africa. *Engineering Geology*, 201, 29-44.
- Schuster, R.L. (1996). Socio-economic significance of landslides. In Turner A.K., Schuster R.L. (Eds.) *Landslides: Investigation and Mitigation*. Transportation Research Board-National Research Council, Special Report, 247, 12-35.
- Süzen, M. L., & Doyuran, V. (2004). Data driven bivariate landslide susceptibility assesment using geographical information system: a method and application to Asarsuyu catchment, Turkey. *Engineering Geology*, 71(3-4), 303-321.
- Tarhan, N. (1989). *Hınıs-Varto (Erzurum-Muş) dolayının jeolojisi ve petrolojisi* (Doktora Tezi). İstanbul Üniversitesi, İstanbul.
- Tarhan, N. (1990). *1/100000 ölçekli açınısama nitelikli Türkiye jeoloji haritaları serisi G-33 paftası* (Rapor No. 35). Ankara: MTA Jeoloji Etütleri Dairesi.
- Tarhan, N. (1998). *1/100000 ölçekli açınısama nitelikli Türkiye jeoloji haritaları serisi F-31 paftası* (Rapor No. 56). Ankara: MTA Jeoloji Etütleri Dairesi.
- Tekin, S., & Çan, T. (2019). Yapay sinir ađları yöntemi ile Ermenek Havzası’nın (Karaman) kayma türü heyelan duyarlılık deđerlendirmesi. *Bilge International Journal of Science and Technology Research*, 3(1), 21-28.
- Temesgen, B., Mohammed, M. U., & Korme, T. (2001). Natural hazard assessment using GIS and remote sensing methods, with particular reference to the landslides in the Wondogenet Area, Ethiopia. *Physics and Chemistry of the Earth, Part C: Solar, Terrestrial & Planetary Science*, 26(9), 665-675.
- Timur, E. (1997). *Yeşirçöl Dađı (Aşkale, Erzurum) ve dolayının jeolojisi ve sedimanter özellikleri* (Doktora Tezi). İstanbul Üniversitesi, İstanbul.
- Timur, E. (2000). Yeşirçöl Dađı (Aşkale, Erzurum) ve dolayının stratigrafisi. *İstanbul Üniversitesi Mühendislik Fakültesi Yerbilimleri Dergisi*, 13(1-2), 85-99.

- van Westen, C. J. (1994). GIS in landslide hazard zonation: a review with examples from the Colombian Andes. In M.F. Price & D.I. Heywood (Eds.), *Mountain environments & geographic information systems* (pp. 135-165), London, UK: Taylor and Francis.
- van Westen, C. J., Rengers, N., & Soeters, R. (2003). Use of geomorphological information in indirect landslide susceptibility assessment, *Natural Hazards*, 30(2003), 399-419.

Effect of Camera Calibration Refreshing on Orthophoto Position Accuracy in UAV Mapping

İHA'larda Kamera Kalibrasyonun Ortofoto Konum Doğruluğuna Etkisi

Cumhur Şahin^{1*} 

¹Gebze Technical University, Faculty of Engineering, Department of Geomatics Engineering, 41400, Gebze, Kocaeli/Türkiye.

ORIGINAL PAPER

*Corresponding author:

Cumhur Şahin
csahin@gtu.edu.tr

doi: 10.48123/rsgis.1207512

Article history

Received: 20.11.2022

Accepted: 20.02.2023

Published: 28.03.2023

Abstract

Unmanned aerial vehicles (UAVs) are autonomous or remote control controlled air vehicles without a pilot. UAVs are aerial platforms capable of carrying non-metric photogrammetric equipment. In this study; the effect of two different calibration values of the camera available on the DJI Phantom 4 Pro equipment to the ortho-photo maps obtained from two different flight heights was investigated. An area within the campus of Gebze Technical University was chosen as a study area. PI 3000 software was used to calibrate the camera and the differences between the calculated parameters and the conventional parameters were determined. Also, the effect of the parameters on position accuracy was investigated. In the photogrammetric stereo model, the rms of Z depends on the picture scale, flight height, base length and the measurement accuracy of image coordinates. Since the measurement accuracy of the image coordinates x, y is also affected by the calibration accuracy, the calibration field independent of the Z value can be used. Geo-referencing and field measurements of the orthophotos produced by the GPS and measurement of the work area from two different heights with UAVs. Office work is the part where orthophotos are produced, georeferenced and analyzed with GPS coordinates of control points. The data obtained in the study reduces the rms value when recalibration is performed at a low flight altitude. However, a similar result could not be obtained for 120 meters flight altitude.

Keywords: UAV, Photogrammetry, Camera calibration, Orthophoto

Özet

İnsansız hava araçları (İHA), pilotsuz otonom veya uzaktan kumandalı hava araçlarıdır. İHA'lar, metrik olmayan fotogrametrik ekipman taşıyabilen hava platformlarıdır. Bu çalışmada; DJI Phantom 4 Pro ekipmanı üzerinde bulunan kameranın iki farklı kalibrasyon değerinin iki farklı uçuş yüksekliğinden elde edilen ortofoto haritalara etkisi araştırılmıştır. Çalışma alanı olarak Gebze Teknik Üniversitesi kampüsü içerisinde bir alan seçilmiştir. Kameranın kalibrasyonu için PI 3000 yazılımı kullanılmış ve hesaplanan parametreler ile konvansiyonel parametreler arasındaki farklar belirlenmiştir. Ayrıca parametrelerin konum doğruluğuna etkisi araştırılmıştır. Stereo modelde yükseklik koh.'sı resim ölçeği, uçuş yüksekliği, baz uzunluğu ve resim koordinatlarının ölçme doğruluğuna bağlıdır. Resim koordinatları x, y nin ölçme doğruluğu da kalibrasyon doğruluğundan etkilendiği için Z değerinden bağımsız kalibrasyon alanı kullanılabilir. Arazi işleri, GPS ile üretilen ortofotoların coğrafi referans ve saha ölçümleri ve İHA'lar ile iki farklı yükseklikten çalışma alanının ölçümü. Büro çalışması, ortofotoların üretildiği, coğrafi referanslarının yapıldığı ve kontrol noktalarının GPS koordinatları ile analiz edildiği kısımdır. Elde edilen veriler ile alçak uçuş irtifasında kalibrasyonun karesel ortalama değerini düşürdüğü görülmüştür. Ancak 120 metre için benzer bir sonuç elde edilememiştir.

Anahtar kelimeler: İHA, Fotogrametri, Kamera kalibrasyonu, Ortofoto

1. Introduction

The effect of unmanned systems in our lives is increasing rapidly. By synchronizing itself to various disciplines, engineering science also tries to use this developing technology in accordance with its purpose of facilitating human life. One of these disciplines, aerial photogrammetry, is applicable for developing different techniques and applications with the expansion of unmanned aerial vehicles.

Aerial photogrammetry is an effective method for measuring larger areas. However, this surveying method previously made with the help of aircraft, can now be used much faster and more efficiently with the development of mini drones which help to minimize cameras in terms of their sizes.

UAVs can provide data with low-cost, high positional and temporal resolution with their GPS receivers, microprocessors, gyroscopes, sensors and communication elements, and these skills have made these systems attractive (Eisenbeiss and Sauerbier, 2011). Currently, since a simple camera, control system and a lightweight UAV are sufficient to collect photogrammetric data, these systems have begun to replace conventional systems. Compared to digital photogrammetric systems, UAV systems that can be installed at very low costs are particularly suitable for the areas with limited widths. Orthophoto, digital terrain model and topographic map production has been widely used by UAVs in recent years (Kršák et al. 2016).

Since UAVs can take images at low altitudes, they can also be used for 3D documentation of archaeological sites and structures (Mozas-Calvache et al. 2012). UAVs are also used for the following purposes: post-disaster emergency response and mapping (Li et al. 2011; Chiang et al. 2012; Zhang et al. 2018; Abdallah et al. 2019), regular measurements for monitoring environmental soil and water changes, deformation tracking (Niethammer et al. 2012), volume calculations for excavation sites and recording of natural resources, monitoring of traffic conditions (Liu et al. 2019). It is seen that it is used in many different important areas such as the documentation of traffic accidents (Pérez et al. 2019), civil infrastructure applications (Greenwood et al. 2019), agricultural applications (Song et al. 2019; Wang et al. 2019; Wu et al. 2019), coastal bathymetries (Simarro et al. 2021). They are also very practical for continuously repeatable flight and mapping studies at low costs, crop forecasting, disease detection and monitoring in the forestry and agriculture sectors (Stagakis et al. 2012), monitoring of fire zones (Krull et al. 2012). Data generation with UAV also serves to create the 3D data infrastructure required for multimedia geographic information systems. The derivation of location-based information using drones is becoming increasingly common.

One of the necessary stages of photogrammetric data processing studies is geometric camera calibration. The dynamic development of photogrammetry has led to the emergence of many calibration methods. Unfortunately, none of them make it possible to directly measure elements of internal orientation. Instead, other physical properties closely related to the determined parameters are measured. On the other hand, the determining factors of the internal orientation are the sources of error that affect the geometric accuracy of the final photogrammetric studies. Camera calibration parameters can be considered pre-calibrated and constant, or their values can be re-estimated in the self-calibrating bundle block adjustment. Various investigations have been carried out on the systematic errors in 3D measurements and strategies have been proposed for systematic error mitigation. A first focus is given to different camera calibration models. One category consists of physical models which mitigate systematic errors according to their assumed physical behavior. In the other category, individual error sources are not explicitly treated. Instead, numerical models are designed to compensate for the total systematic errors. The camera calibration can be performed with two strategies: it can either be performed independently of aerial acquisitions (pre-calibration) or be included in the bundle block adjustment (self-calibration) (Zhou et al. 2020).

In this study; the effect of position errors has been studied and analyzed in orthophoto maps which obtained from two different flight heights with refreshing camera calibration values between conventional camera calibration values for an UAV. The refreshing calibration values are calculated from PI3000 calibration software before flights. The conventional calibration values are came from the standard UAV camera calibration report which are used by the standard mapping software database. An area on the south side of Gebze Technical University Campus has been designated as a study area for this purpose. Orthophotos obtained from flight heights of 60 meters altitude and 120 meters altitude were used for the analysis by utilizing both of the calibration values. 87 points, 6 for georeferencing and 81 for comparison points have been signalized and it's RTK measurements of coordinates within two series with GPS in the orthophoto acquisition area. 6 points are used for georeferencing all orthophotos. Another 81 points were used to compare and analyze the position accuracy of the orthophotos. Thus, the accuracy of orthophotos produced by the software was analyzed only for the differences of calibration values and the accuracy of them was examined.

Flow for the preparation of this article; In the second section of this paper, information about the fundamental concepts of digital photogrammetry is given. The third part, the application of the publication is explained in detail. The fourth section the accuracy of ortho-photos obtained from images acquired by unmanned aerial vehicle are analyzed. In the fifth section, the results obtained at the end of the study are evaluated, some inferences and recommendations are made.

2. Method

Photogrammetry allows the creation of the objects without touching the objects and performs the determination of some of their properties. Photogrammetric method is to automatically connect the basic parameters of at least two different images which cover the same area. The majority of the photogrammetric process sequences are mostly related to matching.

The central perspective projection is usually preferred when performing operations on photogrammetric images. This projection system is called epipolar geometry and provides a considerable limit. When the two images considered, this plane is defined as a plane that contains the epipolar plane object point and the projection center of the two images in three-dimensional space, and it intersects two images with lines that are considered epipolar lines. For example, if the relative orientations of both images are known, the epipolar line can be calculated for the point in one image, and the corresponding point is always found on the epipolar line. So, the image matching problem turns into a one-dimensional task from a two-dimensional task.

The functional model includes the obvious characteristics of the physical condition and the stochastic model provides the probable properties. The mathematical model is a mathematical representation of the points associated with the photograph in the space coordinate system. According to the collinearity, the lights showing the points in the space coordinate system are projected from the image's projection center to the image plane. This process is done in two stages. The first stage is to determine internal orientation parameters. The second stage is to locate the external orientation parameters. The tilt of these images and the coordinates in the space coordinate system are calculated in Equation 1.

$$\begin{bmatrix} x - x_0 \\ y - y_0 \\ -c \end{bmatrix} = \frac{1}{s} \cdot R \cdot \begin{bmatrix} X - X_0 \\ Y - Y_0 \\ Z - Z_0 \end{bmatrix} \quad (1)$$

in equation;

- x, y: Image coordinates,
- x₀, y₀: Image coordinates of the projection center,
- c: Camera focal length,
- s: Scale factor,
- R: Rotation matrix,
- X, Y, Z: Object coordinates,
- X₀ Y₀ Z₀: Object coordinates of the projection center,

$$\begin{aligned} x &= x_0 - c \frac{R_{11}(X - X_0) + R_{12}(Y - Y_0) + R_{13}(Z - Z_0)}{R_{31}(X - X_0) + R_{32}(Y - Y_0) + R_{33}(Z - Z_0)} \\ y &= y_0 - c \frac{R_{21}(X - X_0) + R_{22}(Y - Y_0) + R_{23}(Z - Z_0)}{R_{31}(X - X_0) + R_{32}(Y - Y_0) + R_{33}(Z - Z_0)} \end{aligned} \quad (2)$$

The relation in Equation 2 is the relation to collinearity (linearity). The terms x₀, y₀ and c (f) in this equation represent internal orientation elements, X₀, Y₀, Z₀, and R external orientation elements. Internal orientation elements can be determined by calibration of the sensor, while external orientation elements can be determined by ground control points (GCPs) or GPS, IMU or star cameras. The rotation matrix R can also be created with angles and vectors. Image coordinates have been converted into object coordinates by equation 3. Thus;

$$\begin{aligned} X &= X_0 + (Z - Z_0) \frac{R_{11}(x - x_0) + R_{21}(y - y_0) - R_{31}c}{R_{13}(x - x_0) + R_{23}(y - y_0) - R_{33}c} \\ Y &= Y_0 + (Z - Z_0) \frac{R_{12}(x - x_0) + R_{22}(y - y_0) - R_{32}c}{R_{13}(x - x_0) + R_{23}(y - y_0) - R_{33}c} \end{aligned} \quad (3)$$

can be written. As it can be seen, if the Z coordinate of an object is known, its X and Y coordinates can be obtained. In order to obtain all (X, Y, Z) image coordinates, at least two photographs should be taken from different angles of the same object (Kraus, 1993). The process of finding optimum values with the hardware properties of the camera system is called camera calibration. Pinhole camera calibration was modeled and formulated by Brown (1971).

Camera calibration is intended to reproduce the geometry of rays entering the camera through the projection center at the moment of exposure. The calibration parameters of the camera are: calibrated focal length c_k ; the projection centers in relation to the pictures, determined by x_0 and y_0 — image coordinates of the principal point; lens distortion: radial (K_1, K_2, K_3) and decentering (P_1 and P_2) lens distortion coefficients (Wierzbicki, 2018). For a nonmetric system to be used for measuring purposes, it is necessary to calibrate the digital camera. Many scientists have researched analytical calibration procedures. High values of distortion in non-metric digital cameras have a very negative influence on the accuracy and reliability of the determination of calibration elements. Gašparović and Gajski (2016) suggests that most of the image distortion should be removed in the first step and then the final calibration should be carried out. From the statistical indicators presented the standard deviations of the angular elements of exterior orientation on the same images are up to 2 times better in a two-step calibration. Camera calibration has traditionally been and continues to be the single most significant factor determining the accuracy potential, and to a large extent also the reliability of close-range photogrammetric measurement (Luhmann et al. 2016). Theoretically, the best calibration test field consists of multiple permanent ground control points spread throughout a large area. Indoor calibration is much easier to complete independent of weather conditions. The most commonly used chessboard-style printed calibration test fields are often used in robotics, and allow for the fast and convenient calibration of small industrial cameras (Kolecki et al. 2020) proposed a method for camera calibration consisting of a calibration test field and the relevant software.

The aim of Pérez et al. (2011) is the establishment of an efficient and accurate digital camera calibration method to be used in particular working conditions. A laboratory calibration based on a flat pattern and a field calibration were fulfilled. To carry out the calibration, photomodeler software was used in both cases. In Takahashi and Chikatsu (2015), the authors described and evaluated camera calibration techniques for UAVs using images and orientation parameters of sensor values from mobile devices. The authors executed camera calibration using a test target for evaluating sensor values measured using a mobile camera. Consequently, it is confirmed the same accuracy with normal camera calibration. The test target dimensions used are 640mm, 480mm, 20mm. In the context of UAV camera calibration, assessing the accuracy of calibration parameters computed in various image block configurations by on-the-job self-calibration is still a disputed argument. Roncella and Forlani (2021) created a series of UAV synthetic photogrammetric blocks constructed with varying terrain shape, studied area shape, block control (ground and air), strip type (longitudinal, diagonal and oblique), image observation and control data precision. Empirical airborne test flights in a calibration field have shown how block geometry influences the estimated calibration parameters and how consistent the parameters from lab calibration can be reproduced (Cramer et al. 2017). Hasheminasab et al. (2021) presents automated geometric calibration strategies for UAV-based frame and line camera systems to estimate accurate system calibration parameters without the need for ground control points or manual measurements of tie points.

In calibration, the coordinates of the object points are known and internal orientation elements are searched. Calibration is very important for the accuracy of the camera's imaging ability and all measurement procedures to be done in the image. The ideal condition is usually not achieved during image acquisition. The physical structure of the camera lenses leads to a number of effects in various parts of the image plane. The physical effects of the lenses in projection are called distortion. The cameras have two types of distortion: radial (diametrical) and tangential distortion.

Radial Distortion: This is a fundamental effect that allows the details which need to appear as a straight line in the image to be curved. This effect is a systematic function that varies at different focal lengths and different lenses. Even when all points are well focused, radial distortion distorts the entire image.

Radial distortion formula is presented in Equation 4.

$$\delta r = K_1 r^3 + K_2 r^5 + K_3 r^7 \quad (4)$$

in equation K_1 and K_2 are the distortion parameters, r is the radial distance. Equation 5 shows the components of the x and y directions within the image coordinate system with the effect of this angular change.

$$\delta r x = \delta r (x - x_0) / r \quad (5)$$

Tangential Distortion: The lenses that make up the multi-lens system used in the cameras should be located on the same direction as the centers. In cases where this condition cannot be met, a geometric displacement, called tangential distortion occurs in the image.

If tangential distortion is expressed by the intersection of the coordinate axes of the picture plane, the following are obtained Equation 6 and Equation 7:

$$\delta x = P_1 (r^2 + 2(X - X_0)^2) + 2P_2 (X - X_0)(y - y_0) \quad (6)$$

$$\delta y = P_2 (r^2 + 2(Y - Y_0)^2) + 2P_1 (X - X_0)(y - y_0) \quad (7)$$

P_1 and P_2 are tangential distortion parameters. x, y : image coordinates, x_0, y_0 : image coordinates of the principle point (PP). UAV is an entire system consisting of three basic elements: the unmanned aerial vehicle, the command system and a communication network between them.

Height (Z) in photogrammetry is not a measurement value, it is a calculated value. In photogrammetry, Z value is calculated from x, y image coordinates. Therefore, the accuracy of the height (Z) value mainly depends on the accuracy of the image coordinates x, y values. Height rms. (m_Z); In a stereo model as shown in Equation (8) it depends on the picture scale (m_b), flight altitude (Z), base length (B) and the measurement accuracy parallax difference of the picture coordinates (m_{P_x}). (m_{P_x}) directly depends on the measurement accuracy of the image coordinates.

$$m_Z = m_b \cdot \frac{Z}{B} \cdot m_{P_x} \quad (8)$$

m_{P_x} : is the measurement accuracy in the parallax difference. As a result of the calibration, the x and y image coordinates are corrected. This affects m_{P_x} , as it affects the x and y coordinates. Since the measurement accuracy of the image coordinates x, y is also affected by the calibration accuracy, the calibration field independent of the Z value can be used. Based on this idea, this study was tested.

The correction brought to the focal length c as a result of the calibration directly affects the picture scale. A change in scale, on the other hand, changes the rms of all x, y . The difference in Z values of the terrain points has no direct effect on the stochastic model of the calibration. The values corrected by the camera calibration are the corrections to the x, y values, which are the picture coordinates. As a result, the correction values in the x, y values already directly affect the accuracy in the Z value.

3. Application

The basic equipment used in the study is an unmanned aerial vehicle. Manufacturers of unmanned aerial vehicles, which have recently been used for civilian purposes, perform purpose-specific productions. Detection of maximum flight height, camera features and the most suitable hardware can be done depending on the problem by the manufacturers who offer various solutions. The purpose of this study is to investigate and analyze the effect of coordinate positioning for orthophoto maps obtained from two different flight heights with refreshing camera calibration between conventional camera calibration data for an unmanned aerial vehicle has been studied and analyzed. The refreshing camera calibration values obtained from PI3000 calibration software in planar calibration field before flights. Two orthophotos obtained from each flight height (60 meters altitude and 120 meters altitude) were used for the analysis by utilizing both of the refreshing and conventional camera calibration values. Figure 1. shows the flowchart that explains the process step of the study.




Figure 1. Flowchart of the study

Study area covers some part of the area on the south side of Gebze Technical University Campus. An area of approximately 15 hectares is decided as the study area which has shown in Figure 2.



Figure 2. Study area in Gebze Technical University Campus

The preferred unmanned aerial vehicle is In summary, while recalibrating at 60 meters flight altitude with the data obtained in the study reduces the square mean value, the calibration process at 120 meters flight altitude does not have a significant effect on the accuracy values for this study. This drone which is 1380 gram has four propellers. The camera, which is connected to the body with an integrated gimbal, has a resolution of 12 Megapixels. DJI Phantom, which can stay in the air for 28 minutes, can speed up 20 meters in 4 seconds. The hardware, which is operated with lithium batteries, has four sensors. These sensors prevent a possible collision. It provides an advantage in terms of flight safety compared to its counterparts. Table 1 illustrates technical specifications of DJI Phantom 4 Pro and Table 2 presents technical specifications of the camera equipment used in DJI Phantom 4 unmanned aerial vehicle.

Table 1. Technical specifications of DJI Phantom 4 Pro UAV

| | |
|--------------------------------|-------------|
| Weight | 1380 gr. |
| Maximum Lift-off Rate | 6 m/s. |
| Maximum Descent Rate | 4 m/s. |
| Maximum Rate | 20 m/s. |
| Maximum Height | 6000 m. |
| Maximum Flight Duration | 28 minutes |
| Satellite System | GPS/GLONASS |

Table 2. Technical specifications of the camera of DJI Phantom 4 aerial vehicle

| | |
|---------------------------------|-------------------------|
| Sensor | 1/2.3" Effective Pixel |
| Lens | f/2.8 |
| ISO Range | 100 - 1600 (photograph) |
| Electronic Shutter Speed | 8 s to 1/8000 s |
| Maximum Image Size | 4000×3000 |
| Photograph | JPEG, DNG (RAW) |

Geo-referencing of orthophotos produced by UAV photogrammetry and geodesic land work was carried out in order to investigate point position accuracy between different flight-height and refreshing camera calibration parameters and conventional camera calibration parameters.

In geodesic work, the control points required for geo-referencing and analysis of the point accuracy. The clear and sharp detail points to in the photographs taken by the UAV were determined as the control points. These points were measured with the GNSS device. The measuring process of ground control points was made with the Leica Viva GS15 GNSS device and the coordinates were obtained in 2005.00 EPOK in the ITRF96 datum system. For this purpose, measurements were made in two different time periods. Three minutes of measurement was made at each control point. Coordinates which were provided by two different series were averaged. In the study, an accuracy study is carried out based on geodesic coordinates from the GPS measurement within RTK method. After measuring the control points, photographs of the study area were taken with the UAV.

As it is illustrated in Figure 4, the calibration images from 5 different projection points of the planar calibration area of PI-3000 software with the DJI Phantom 4 Pro standard camera are used for calibration in PI-3000 software and the values obtained as a result of calibration are combined for the purpose of production of orthophotos as a refreshing camera calibration parameters. The calibration page used to determine the projection parameters and distortion function of the camera is in Figure 3.




Figure 3. Calibration sheet and angles of photography

Orthophotos produced with calibration values obtained using PI3000 software are called orthophotos produced with calculated parameters. Figure 4 shows calibration results for image distortion in PI3000 software. Orthophotos produced with different calibration values obtained by flights of the same height will offer the possibility to compare the values. Both of the calibration values which used in the study have been presented in Table 3.




Figure 4. DJI Phantom 4 PRO camera calibration in PI3000 software

Table 3. Normal/Parameterized calibration values

| Camera | c (mm) | x ₀ (mm) | y ₀ (mm) | k ₁ | k ₂ | p ₁ | p ₂ |
|--------------------------|---------|---------------------|---------------------|----------------|----------------|----------------|----------------|
| Conventional (Standard) | 3.61000 | 3.15875 | 2.36906 | -0.001358 | -0.001605 | -0.000909 | -0.001138 |
| Calibration (Refreshing) | 3.51101 | 3.06364 | 2.25330 | 0.000763 | 0.000019 | -0.000521 | 0.000473 |

The imaging study was performed with the standard digital camera integrated into the DJI Phantom 4 Pro UAV system in Figure 5.

Information such as flight height, horizontal and vertical speed could be read on the display of the image transfer system and photographs from two different heights were taken with UAV's GPS mode (60 m altitude and 120 m altitude). During imaging section, overlay rates were 70% transverse and 80% longitudinal.



Figure 5. DJI Phantom 4 pro drone set

For covering the study area; a total of 307 images from a flying height of 60 meters and 112 images from a height of 120 meters were acquired. Figure 6 has shown the flight line and the points of imaging from a height of 60 meters. Figure 7 has shown the flight line and the points of imaging from a height of 120 meters.



Figure 6. Imaging Plan for flying height of 60 meters altitude



Figure 7. Imaging Plan for flying height of 120 meters

The normal parameters which are automatically calculated by the orientation parameters owned by the camera and shown in the PIX4D software integrated on DJI Phantom 4 PRO, are used without making any changes. Orthophotos produced with these calibration parameters are denominated with the names which correspond to the calculation made by normal parameters. Images have been automatically matched after flights from 60 m and 120 m altitudes, the default internal and external orientation parameters are used, and they are installed into the PIX4D software. 81 points are used as the ground control points for comparison in the final stage of the study. This process is only functional to control data which occur as a result of different flights and refreshing camera parameters.

The stages of orthophoto production in PIX4D are as follows. First, aerial images are uploaded to the program. The projection system and earth zone of the project are introduced to the program. This process is intended to transform geographic coordinates. Ground control points are added to the program and the image coordinates of the control points on the images are measured.

This process is done separately with conventional calibration parameters for 60 meters altitude and 120 meter altitude flights. Additionally, with refreshing camera parameters from the PI3000 software, orthophotos for 60 meters altitude and 120 meters altitude are also produced.

As a result of all this study, 4 orthophotos were produced. 2 out of 4 orthophotos which were produced with refreshing camera calibration parameters (for 60 meters and 120 meters) are shown in Figure 8 and Figure 9.




Figure 8. Orthophotos obtained from the flight height of 60 meters altitude with normal and parameterized calibration values




Figure 9. Orthophotos obtained from the flight height of 120 meters altitude with normal and parameterized calibration values

4. Result and Analysis

Error vectors between coordinates which are considered conventional camera calibration between refreshing camera parameters, obtained as a result of geodesic measurement with control point coordinates read from the orthophoto obtained using images from flight height of 60 meters altitude and conventional calibration parameters are shown in Figure 10 and Figure 11. When Figure 10 and Figure 11 are compared, the control points above the building have a higher standard deviation than the points on the ground. In addition, the accuracy of the ground control points towards the center of the study area increases.




Figure 10. Point position vectors between a normal parameter orthophoto and ground control points (GPS) produced from a height of 60 meters altitude




Figure 11. Point position vectors between a calibrated parameter orthophoto and ground control points (GPS) produced from a height of 60 meters altitude

Error vectors between coordinates which are considered conventional camera calibration between refreshing camera parameters, obtained as a result of geodesic measurement with control point coordinates read from the orthophoto obtained using images from flight height of 120 meters altitude and conventional calibration parameters are shown in Figure 12 and figure 13.




Figure 12. Point position vectors between a normal parameter orthophoto and ground control points (GPS) produced from a height of 120 meters altitude




Figure 13. Point position vectors between a calibrated parameter orthophoto and ground control points (GPS) produced from a height of 120 meters altitude

According to results, which focuses on investigating and analyzing the differences for coordinates between orthophotos obtained by flights from altitudes of 60 m and 120m. Stabilizing the observation area, the hardware and software features is important for determining the sensitivity differences in area-sample ranges at different heights.

In addition, the use of different flight heights and calibration parameters and its effects on X and Y position accuracies are shown. It is shown that the standard deviation of the results decreases. It is also thought that coarse errors usually occur when the operator evaluation is performed. Analysis is done in Table 4 for X and Y axes because there are high area errors on building roofs and established control points which are at a different height than the ground level. The differences are obvious. As the height of the control points in the study area increases, there is also an increase in standard deviation. The chart in Table 4 is presented in Figure 14 and Figure 15.

Table 4. Standard deviation table

| Position RMS | 60m Conventional | 60m Refreshing | 120m Conventional | 120m Refreshing |
|--------------|------------------|----------------|-------------------|-----------------|
| Std X (m) | 0,035389685 | 0,033469707 | 0,022534359 | 0,037740845 |
| Std Y (m) | 0,057888305 | 0,055663007 | 0,048610602 | 0,058657069 |




Figure 14. Standard deviation

When the above charts and analyses are examined;

The results of the course incorrect points and the control points marked above the building are shown in the tables above. When these tables are examined, the standard deviation of the "Y" axis coordinates is greater than the "X" axis coordinates. Although the position accuracy of X's is higher, it varies depending on the flight direction (Table 4).

When examining standard deviation graphs from flights of 60 and 120 meters, a flight height of 120 meters indicates that the camera gives better results than other samplings (Figure 14).

Between orthophotos made with both normal and calibration of flights made of 60 meters altitude, the position accuracy ratio of the ortho-photo with normal values is higher than the calculated orthophoto parameter. In both cases, the standard deviation of the "Y" coordinate is higher than the "X" coordinate (Figure 14).

In the comparison obtained from orthophoto, which is created with images taken from 120 meters altitude, the most accurate measurement is obtained at this height compared to others in the controls which are made using both normal and calibration parameter. A standard deviation from 0.035 m. to 0.033 m. is observed at the "X" coordinates, while the "Y" coordinates differ between 0.057 m. and 0.055 m. (Figure 14).

As a result of balancing the photos obtained with normal parameters with flights at a height of 120 m, both "X" and "Y" standard deviations are between 0.05 m. and 0.07 m. and they are in their closest position to each other. The closest accurate sample in this study is the sample made at a flight height of 120 m. for conventional values (Figure 14). The evaluation of the images taken from 120 m with the refreshing calibration parameters, It has seen that the "X" increases from 0.022 m. to 0.037 m. Also, the standard deviation of "Y" increases from 0.048 m. to 0.058 m. As a result of all these analyses, it is interpreted that having a standard error in the "Y" coordinates or containing more errors than "X" may be caused by an axis error. Refreshing 60 meters gives the result we expect. Refreshing at 120 meters does not give the expected result. As the flight altitude increases, the calibration process does not have a significant effect on the accuracy values.

5. Conclusion

The use of unmanned systems as a measuring tool, which are widely used today and are going to be used in many disciplines brings forward many issues. The most important of these is positional accuracy and precision. In this study, using normal and calculated calibration parameters for heights of 60 meters altitude and 120 meters altitude, positional accuracy and standard deviations are tested and analyzed for different situations and conditions. 81 points were installed on the test area of the study. Of these, 45 are located on the surface and 36 are located on the roofs and terraces of the buildings. Ground control points are measured with a GPS measurement. Calibration parameters were calculated with the use of the program called PI 3000. Aerial photos were taken by DJI Phantom 4 Pro Unmanned Aerial Vehicle (UAV). Resolution of its camera was 12 MP. Orthophoto production was obtained by a commercial software called PIX4D within geo-referencing. The ground sample range of orthophoto obtained from an elevation of 60 m is 2.62 cm and has a flight length of 6000 m. It includes 307 aerial images. Because the overlay rate is constant, the number of images is higher compared to 120 m. The ground sample range of orthophoto obtained from an elevation of 120 m is 5.25 cm and has a flight length of 3200 m. A total of 112 images were taken at this height and the orthophoto has been obtained.




Figure 15. Coordinate differences about height of point for flight height of 60 meters altitude




Figure 16. Coordinate differences graphic for 60 meters altitude

When Figure 15 and Figure16 are examined, it is observed that the control points in orthophotos obtained from the flight from 60 meters have lower positional differences when compared with geodesic coordinates. Especially at points where the control points used on the land shows sudden changes of height, it is seen that calibration renewal provides a significant benefit. Based on the overall height profile of the land, it can be said that the positional values of all points improve. In terms of point positional differences, positional differences are clustered in near-zero areas in this low-distance flight.

Coordinate Differences About Height of Points for Flight Height of 120m




Figure 17. Coordinate differences about height of point for flight height of 120 meters altitude




Figure 18. Coordinate differences graphic for 120 meters altitude

When Figure 17 and Figure 18 are examined, it is observed that the control points in orthophotos obtained from the flight from 120 meters have higher positional differences when compared with geodesic coordinates. Especially at points where the control points used on the land shows sudden changes of height, it is seen that calibration renewal provides a limited benefit. These renewed calibration values and distortion parameters must be used in place of default software calibration values in low distance flight orientations.

In the literature, there are studies focused on the field calibration method. Pérez et al. (2011) presents a study comparing laboratory and field calibration. In laboratory calibration, the images covered the calibration grid pattern included in package of Photomodeler. The grid pattern was placed on the floor and three images were collected from each of the pattern's four sides. The field test used in the study was a flat surface located and a set of 67 target points were placed. The calibration field area was 25 x 25 m approximately and the altitude flight over ground was 50 m. The laboratory calibration has a final total error of 1.940 pixels. The field calibration has a total error of 0.282 pixels. Field calibration method reduced the final total error obtained in the previous laboratory calibration. Furthermore the overall rms obtained from both methods are similar. In this study, the default calibration parameter of the DJI Phantom 4 Pro and the calibration parameters obtained from the PI3000 software were examined. In summary, while recalibrating at 60 meters flight altitude with the data obtained in the study reduces the square mean value, the calibration process at 120 meters flight altitude does not have a significant effect on the accuracy values.

References

- Abdallah, A., Ali, M. Z., Mistic, J., & Mistic, V. (2019). Efficient security scheme for disaster surveillance UAV communication networks. *Information, 10*(2), 43. doi: 10.3390/info10020043.
- Brown, D. C. (1971). Close-range camera calibration. *Photogrammetric Engineering, 37*(8), 855-866.
- Chiang, K. W., Tsai M. L., & Chu C. H. (2012). The development of an UAV borne direct georeferenced photogrammetric platform for ground control point free applications. *Sensors, 12*(7), 9161-9180.
- Cramer, M., Przybilla, H. J., & Zurhorst, A. (2017, September). UAV Cameras: overview and geometric calibration benchmark. In *International Conference on Unmanned Aerial Vehicles in Geomatics, 2017. Proceedings.* (pp. 85-92). ISPRS.
- Eisenbeiss, H., & Sauerbier, M. (2011). Investigation of UAV systems and flight modes for photogrammetric applications. *Photogrammetric Record, 26*(136), 400-421.
- Gašparović, M., & Gajski, D. (2016, July). Two-step camera calibration method developed for micro UAV's. In *XXIII ISPRS Congress, 2016. Proceedings.* (pp. 829-833). ISPRS.
- Greenwood, W. W., Lynch J. P., & Zekkos D. (2019). Applications of UAVs in civil infrastructure. *Journal of Infrastructure Systems, 25*(2), 9-15.

- Hasheminasab, S. M. Zhou, T., LaForest, L. M., & Habib, A. (2021). Multiscale image matching for automated calibration of UAV-based frame and line camera systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *14*, 3133-3150.
- Kolecki, J., Kuras, P., Pastucha, E., Pyka, K., & Sierka, M. (2020). Calibration of industrial cameras for aerial photogrammetric mapping. *Remote Sensing*, *12*(19), 3130. doi:10.3390/rs12193130.
- Kraus, K. (1993). *Photogrammetry, Vol. 1: Fundamentals and Standard Processes*. Bonn, Germany: Dümmlers.
- Kršák, B., Blištan, P., Paulíková, A., Puškárová, P., Kovanic, L., Palková J., & Zelíznaková, V. (2016). Use of low-cost UAV photogrammetry to analyze the accuracy of a digital elevation model in a case study. *Measurement*, *91*, 276-287.
- Krull, W., Tobera, R., Willms, I., Essen, H., & Wahl, N. (2012). Early forest fire detection and verification using optical smoke, gas and microwave sensors. *Procedia Engineering*, *45*, 584-594.
- Li, C. C., Zhang, G. S., Lei, T. J., & Gong, A. (2011). Quick imageprocessing method of UAV without control points data in earthquake disaster area. *Transactions of Nonferrous Metals Society of China*, *21*(3), 523-528.
- Liu, X. F., Peng, Z. R., & Zhang L.Y. (2019). Real-time UAV rerouting for traffic monitoring with decomposition based multi-objective optimization. *Journal of Intelligent & Robotic Systems*, *94*(2), 491-501.
- Luhmann, T., Fraser, C., & Maas, H. G. (2016). Sensor modelling and camera calibration for close-range Photogrammetry. *ISPRS Journal of Photogrammetry and Remote Sensing*, *115*, 37-46.
- Mozas-Calvache, A. T., Perez-Garcia, J. L., Cardenal-Escarcena, F. J., Mata-Castro, E., & Delgado-Garcia, J. (2012). Method for photogrammetric surveying of archaeological sites with light aerial platforms. *Journal of Archaeological Science*, *39*(2), 521-530.
- Niethammer, U., James, M. R., Rothmund, S., Travelletti, J., & Joswig, M. M. (2012). UAV-based remote sensing of the super-sauze landslide: Evaluation and results. *Engineering Geology*, *128*, 2-11.
- Pérez, J. A., Goncalves G. R., Rangel, J. M. G., & Ortega P. F. (2019). Accuracy and effectiveness of orthophotos obtained from low cost UASs video imagery for traffic accident scenes documentation. *Advances in Engineering Software*, *132*, 47-54.
- Pérez, M., Agüera, F., & Carvajal, F. (2011, September). Digital camera calibration using images taken from an unmanned aerial vehicle. In *ISPRS Zurich 2011 Workshop, 2011. Proceedings*. (pp. 167-171). ISPRS.
- Roncella, R., & Forlani, G. (2021). UAV block geometry design and camera calibration: A simulation study. *Sensors*, *21*(18), 6090. doi:10.3390/s21186090.
- Simarro, G., Calvete, D., Plomaritis, T.A., Moreno-Noguer, F., Giannoukakou-Leontsini, I., Montes, J., & Durán, R. (2021). The influence of camera calibration on nearshore bathymetry estimation from UAV videos. *Remote Sensing*, *13*(1), 150. doi: 10.3390/rs13010150.
- Song, F., Dan, T., Yu, R., Yang, K., Yang, Y., Chen W. Y., Gao, X. Y., & Ong, S. H. (2019). Small UAV-based multi-temporal change detection for monitoring cultivated land cover changes in mountainous terrain. *Remote Sensing Letters*, *10*(6), 575-581.
- Stagakis, S., Gonzalez-Dugo, V., Cid, P., Gullien, M. L., & Zarco-Tejada, P. J. (2012). Monitoring water stress and fruit quality in an orange orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. *ISPRS Journal of Photogrammetry and Remote Sensing*, *71*(2012), 47-61.
- Takahashi, Y., & Chikatsu, H. (2015, May). Camera calibration for UAV application using sensor of mobile camera. In *Indoor-Outdoor Seamless Modelling, Mapping and Navigation, 2015. Proceedings*. (pp. 239-242). ISPRS.
- Wang, F. L., Wang, F. M., Zhang, Y., Hu, J. H., Huang, J. F., & Xie, J. K. (2019). Rice yield estimation using parcel-level relative spectra variables from UAV-based hyperspectral imagery. *Frontiers Plant Science*, *10*, 453. doi:10.3389/fpls.2019.00453.
- Wierzbicki, D. (2018). Multi-camera imaging system for UAV photogrammetry. *Sensors*, *18*(8), 2433. doi:10.3390/s18082433.
- Wu, Z. C., Ni, M., Hu, Z. W., Wang, J. J., Li, Q. Q., & Wu, G. F. (2019). Mapping invasive plant with UAV-derived 3D mesh model in mountain area-A case study in Shenzhen Coast, China. *International Journal of Applied Earth Observation and Geoinformation*, *77*, 129-139.
- Zhang, N., Zhang, X. L., Yang, G. J., Zhu, C. H., Huo, L. N., & Feng, H. K. (2018). Assessment of defoliation during the *Dendrolimus tabulaeformis* Tsai et Liu disaster outbreak using UAV-based hyperspectral images. *Remote Sensing of Environment*, *217*, 325-337.
- Zhou, Y., Rupnik, E., Meynard, C., Thom, C., & Pierrot-Deseilligny, M. (2020). Simulation and analysis of photogrammetric UAV image blocks-influence of camera calibration error. *Remote Sensing*, *12*(1), 22. doi:10.3390/rs12010022.

Flood Inundation Mapping with Supervised Classifiers: 2021 Gediz Plain Flood

Denetimli Sınıflandırıcılarla Taşkın Haritalaması: 2021 Gediz Ovası Seli

Enis Arslan^{1*} , Serkan Kartal² 

¹Çanakkale Onsekiz Mart University, Department of Computer Engineering, 17020, Çanakkale/Türkiye.

²Çukurova University, Department of Computer Engineering, 01380, Adana/Türkiye.

ORIGINAL PAPER

*Corresponding author:

Enis Arslan
enisarslan@gmail.com

doi: 10.48123/rsgis.1220879

Article history

Received: 18.12.2022
Accepted: 15.03.2023
Published: 28.03.2023

Abstract

Generation of flood inundation maps is beneficial in flood risk assessment and evaluation. Flood inundation mapping can be achieved by many remote sensing techniques like change detection (CD) with thresholding and machine learning-based (ML) methods. Optical and synthetic aperture radar (SAR) imagery are widely used, provided by different satellite systems. This study used Sentinel-1 SAR and Sentinel-2 MSI satellite data in Google Earth Engine (GEE) with supervised ML algorithms. Gediz Plain, Turkey was selected as the study area, which is an agricultural area covered mostly by croplands. A flood event that occurred on February 2, 2021, was examined and flood inundation map for the study area was composed. Support Vector Machines (SVM), Random Forest (RF) and K-Nearest Neighbor (KNN) ML algorithms were selected and models were trained with manually created labelled data in GEE. Also, CD was applied on after and before event SAR images in a traditional approach. RF classifier performs best in Sentinel-2 MSI imagery with 94% overall classification accuracy where KNN classifier gives 93.3% accuracy value for Sentinel-1 SAR dataset, indicating the robustness of SAR imagery for all-weather conditions.

Keywords: Flood mapping, GEE, Classifier, Sentinel-1, Sentinel-2

Özet

Taşkın haritalarının oluşturulması, taşkın sebepli risklerin değerlendirilmesinde oldukça faydalıdır. Sel-taşkın haritalaması, eşikleme ile değişiklik tespiti (DT) ve makine öğrenimi tabanlı (MÖ) yöntemler gibi birçok uzaktan algılama tekniği ile gerçekleştirilebilmektedir. Bu çalışmada farklı uydu sistemleri tarafından sağlanan optik ve sentetik açıklıklı radar (SAR) görüntüleri yaygın olarak kullanılmaktadır. Bu çalışmada, denetimli MÖ algoritmaları ile Google Earth Engine'de (GEE) Sentinel-1 SAR ve Sentinel-2 MSI uydu verileri kullanılmıştır. Çalışma alanı olarak Türkiye'nin Gediz Ovası seçilmiştir ve bu alan çoğunlukla ekili arazilerle kaplıdır. Bu çalışmada 2021 yılı Şubat ayının ikinci günü meydana gelen taşkın olayı incelenmiş ve çalışma alanı için taşkın haritası oluşturulmuştur. Çalışma için, Support Vector Machines (SVM), Random Forest (RF) ve K-nearest Neighbor (KNN) MÖ algoritmaları seçilmiş ve modeller GEE'de manuel olarak oluşturulan etiketlenmiş verilerle eğitilmiştir. Ayrıca geleneksel yaklaşımla olay öncesi ve sonrası SAR görüntülerine DT uygulanmıştır. RF sınıflandırıcısı, %94 genel sınıflandırma doğruluğu ile Sentinel-2 MSI görüntülerinde en iyi performansı gösterirken, KNN sınıflandırıcısı, Sentinel-1 SAR veri kümesi için %93,3 doğruluk değeri vererek SAR görüntülerinin tüm hava koşulları için uygunluğunu göstermektedir.

Anahtar kelimeler: Taşkın haritalaması, GEE, Sınıflandırıcı, Sentinel-1, Sentinel-2

1. Introduction

Floods are natural disasters that occur as inundations after intense rainfall. They may cause loss of life, property damage, and communication line and transportation system failures in urban areas. It is the deadliest kind of disaster with a 43.5% death ratio (Chen et al. 2021). In remote sensing, satellite data with various spatial and temporal resolutions are widely used in a cost-effective way to determine the extent of flooding over large regions. Satellite imagery are introduced in two types: optical and synthetic aperture radars (SAR). Landsat and Sentinel-2 missions present optical imagery from visible bands to shortwave infrared (SWIR). On the other hand, Sentinel-1 mission provide SAR imagery with two polar-orbiting satellites, free of charge (Clement et al. 2018).

Nowadays, Satellite-borne SARs are used in a large extent for earth observation due to their near real-time all-weather and all-time capabilities. SAR systems emit radar signals to penetrate obstacles like clouds (Solbø and Solheim, 2005). SAR systems basically operate on backscatter radio signals reflecting from the surface of terrains like land or water and acquired by a satellite sensor. Radio signal strength depends on the roughness of the surface and rough surfaces like water are seen as dark in the images. Also, there are some drawbacks of SAR images where returning of the radio signal depends on some parameters like rain and winds that may cause waves on the water terrain (Čotar et al. 2016). Many satellite systems provide SAR images for use such as Sentinel-1, RADARSAT-1/2, TerraSAR-X and ENVISAT ASAR. Sentinel-1A and Sentinel-1B satellites can provide images with a frequency of 6 days but when they operate together with two orbits, they can observe any point of the earth in every six days.

SAR images can be used in various applications like flood extent mapping (Cao et al. 2019), water surface detection (Martinis et al. 2015), flood depth estimation (Cian et al. 2018), flooded vegetation detection (Klemas, 2013), flood risk assessment (Pramanick et al. 2022), oil spill detection (Topouzelis, 2008) and ship detection (Chang et al. 2019). When SAR-based flood extent mapping is the case, many methods and their combinations are used by the researchers. These are, texture analysis (Pradhan et al. 2014), region growing (Baghi and Karami, 2017), supervised classification (Benoudjit and Guida, 2019), unsupervised classification (Carincotte et al. 2006) and histogram thresholding (Brown et al. 2016). Texture analysis is a technique that examines and calculates textures in an image by using the first order and second order statistics. The region growing method calculates similarities between neighboring pixels and creates uniform regions while detecting edges. Supervised classification methods require training images labelled as flooded/non-flooded. Training images can be any image of the event including flooded and non-flooded areas. These areas can be manually labelled before training. Also, there are some techniques used to prepare training images automatically by applying a log ratio to an image captured before and after the flood event. Following the preparation of the dataset, any supervised classifier can be used for the classification of the land cover. Contrary to supervised methods, no labelled datasets are required for unsupervised classification methods. Unsupervised methods are mostly used for change detection in order to compose difference images. Change detection process provides a difference image by comparing the flooding time image with a previous dry scene of the study area. Generally, a threshold is applied to the difference images to classify the flooded areas. Among all these methods, histogram thresholding is the most common technique used for flood detection, which basically measures the backscatter signal from the terrain. Initially, a threshold is determined by examining the histogram of the event image, and selected threshold is applied to the image to classify it as flooded and non-flooded. This threshold can be defined manually by visual observation or automatically, by using Schumann's (Schumann et al. 2010) method, which calculates a global threshold value from the histogram by using Otsu's method (Kurita et al. 1992).

The objective of this study is to extract the inundation map of a flood event on February 2, 2021, in the Gediz plain, located in the western region of Turkey, by using remote sensing data and techniques. The Gediz plain is frequently subject to floods. Local news media agencies give information about the floods on two different days in February 2021. According to one news, the first heavy rainfall in the region was on 02.02.2021. Other news dated 14.02.2021 claims rainfall during a week. This region is economically important with fertile croplands, mostly as vineyards. In 1951, Turkish ministry council has decided a reserve area of 400 m around the Gediz river as a precaution to flood events. Flood mapping studies for this region can help officials to take necessary measures in advance. In this study, non-parametric supervised classifiers Random Forest (RF) (Breiman, 2001), Support Vector Machines (SVM) (Hsu et al. 2016), and K-Nearest Neighbor (KNN) (Duda et al. 1973) with optical and synthetic aperture radar (SAR) imagery were used to examine the flood extent. Performances of these classifiers were also evaluated on the study area. In a recent study (Ozkan and Tarhan, 2016), a flood risk assessment of the Gediz, Bakırçay, and Menderes regions was presented. Our study differentiates from this study by specifically focusing on flood mapping on a specific event using remote sensing techniques. To our knowledge, no study has been performed with remote sensing techniques with supervised classifiers in our study area.

2. Study Area

The study area was selected as Gediz River Delta which is located in the Aegean region, in the western part of Turkey. Gediz Delta (38°300 N, 26°550 E), covering nearly an area of 400 km², is an ecosystem formed by aluvions drained by Gediz River. Gediz River starting from Kütahya (Murat and Şaphane mountains) to Uşak and Manisa provinces ends in İzmir province, which is the major province of the region with nearly 4.3 million habitants. Gediz Delta is known with its fertile agricultural lands. Menemen plain, a part of the region, supplies nearly 40% of the spinach production of Turkey. Also cotton, fruit and legumes are the main farming items in the region (ÇOB, 2007). Gediz Delta, with a biogeographic diversity host nearly 80,000 wetland birds in a year (Arslan et al. 2021). The study area is given in Figure 1.




Figure 1. Study area

Study area, mainly located in Manisa province, with a Mediterranean climate, hot dry summer and mild winter conditions. Mean annual rainfall of 724 mm, mostly in winter, 123 mm in January. Long-term mean annual temperature is 17°C, with minimum and maximum values of 3°C and 10°C in January, respectively. Highest daily rainfall was recorded on 12.23.1986 with the value 163,5 mm (MGM, 2023).

Gediz Delta was selected for investigation because of the recurrent flooding events on the fertile agricultural fields. According to news media in April, 2012, heavy rainfall over levelled the Demirköprü Dam and officials released the extent water out of the Dam in a controlled way. But this caused 30 thousand m² area to inundate and crops were damaged.

3. Data and Methods

In this study Sentinel-1 SAR and Sentinel-2 MSI data products are used for flood inundation mapping of the Gediz plain. For the flood event, Sentinel-2 MSI data was used for validation by using spectral indices due to the absence of ground truth.

Actually, in this study, Sentinel-2 MSI data provided little help in the validation process because of the high cloudiness level on the event day and following days. A special SWIR composite obtained from Sentinel-2 MSI satellite with bands B12, B2 and B3, apparently showed the flooded areas, with acceptable cloud disturbances. Also, this composite was useful for defining polygons to be used for training and validation purposes. Google Earth Engine (GEE) (Gorelick et al. 2017) is a cloud platform provided by Google Inc. GEE provides high-computing power with an extensive set of satellite data and several machine learning (ML) algorithms. GEE platform was used for data access, computing, and visualization.

3.1 Data

In the scope of this study, images of Sentinel-1 SAR and Sentinel-2 MSI satellite systems introduced by European Space Agency (ESA) were used. A huge amount of satellite data is now available and reachable from GEE without charge. Sentinel-1 SAR data (VV and VH polarizations) was used for the initial observation of the flood inundation. On the event date (02-02-2021) Sentinel-1 SAR image was available while Sentinel-2 MSI image was not available for the event date. The earliest optical image was on 06-02-2021 with 10.28% cloudy pixel average. The satellite data used is given in Table 1.

Table 1. Satellite data obtained and used in GEE as before/after a flood event

| Dataset | Before event dates | After event dates | Spatial Resolution (m) |
|--|--------------------------|-------------------|---|
| Sentinel-1 SAR GRD:C Band (VV-VH) | 2020-12-23 | 2021-02-03 | 10 m for VV and VH polarizations |
| Sentinel-2 MSI Level 2-A | 2021-01-17 2021-01-19 | 2021-02-06 | 10 m for bands 'B2', 'B3', 'B4', 'B8', 20 m for bands 'B11', 'B12' |

3.1.1 Selection of Training and Validation Data

Using supervised classification algorithms in GEE requires labelled data. A collection of accurate training samples is required to avoid uncertain classification results. For this purpose, training data and validation data were prepared by manual interpretation of the study area as polygons by using the GEE interface. Extreme care was taken to select polygons as homogenous as possible. Polygon counts are given in Table 2 where S2 and S1 acronyms denote Sentinel-2 and Sentinel-1 satellites, respectively.

Table 2. Polygon statistics which represent class labels as feature collections

| S2 | water | non-vegetated | vegetated | forest | cloud |
|-----------------|-------|---------------|-----------|--------|-------|
| Train | 30 | 30 | 30 | 30 | 10 |
| Validate | 30 | 30 | 30 | 30 | 10 |
| S1 | water | other areas | | | |
| Train | 20 | 20 | | | |
| Validate | 20 | 20 | | | |

In Table 2, land cover class labels for Sentinel-2 imagery (SWIR composite) were defined as: water, non-vegetated, vegetated, forest, and cloud. Cloud was added as a feature in order to visualize the final classification map easily. On the other hand, another set of polygons were created for Sentinel-1 SAR imagery classification as water and other areas. Distinct polygons were selected for training and validation processes. For each class, polygons are obtained by polygon tool on GEE.

Different approaches were tried to compose accurate polygons. Spectral indices were insufficient to demonstrate the flooded areas because of the cloud effect. Therefore, a SWIR composite (bands B12, B2 and B3), given in Figure 2, was used to label areas covered with water for water class. Other class labels were selected from the most evident spectral indices image (NDWI).



Figure 2. SWIR composite (RGB: B12, B2, B3) of the study area

In Figure 2, flooded areas can be seen in blue color mostly surrounded by clouds. This image composite was the most obvious one for the flood event when compared to others. For the SAR classification, Sentinel-1 SAR after event image (VH) was used to determine the polygons.

3.2 Methods

This study is composed of two stages. In the first stage, generic SAR preprocessing and change analysis methodology were applied to find out the inundated areas. In the second stage, supervised classification was applied to optical and SAR images, distinctly. The whole methodology workflow of the study is given in Figure 3.




Figure 3. Methodology workflow of the study

Satellite data was filtered with region of interest (ROI) i.e. study area, bands needed (VV and VH), event dates, and pass direction (DESC) for Sentinel-1. The resulting image was clipped and mosaicked. A speckle filter with a radius of 100m was applied for smoothing. On the other hand, for Sentinel-2 Optical images, a cloud filter and time frame filter were applied for the nearest event dates using the same ROI. Normalized Difference Vegetation Index (NDVI) (Rouse et al. 1974), Normalized Difference Water Index (NDWI) (McFeeters, 1996) Normalized Difference Moisture Index (NDMI) (Hardisky et al. 1983), and Modified NDWI (MNDWI) (Xu, 2006) spectral indices were calculated for the resulting Sentinel-2 collections. Spectral indices were not successful in visualizing flooded areas because of the cloudiness of the optical image. NDWI was slightly better when compared to others, and this image was selected for the classification of the study area. The SWIR composite was composed to observe floodwater and used for creation of polygons as features (Figure 3).

3.2.1 SAR Change Detection

Sentinel-1 SAR data was used to expose inundated areas with a change detection method. Although there are several methods for change detection like post classification comparison as an unsupervised method, image differencing, image rationing and Principal component analysis (PCA). In this study, change detection was applied with image differencing technique.

This technique operates as subtracting pixel values (as digital numbers) for each corresponding bands and application of a threshold value to each band image to delineate the resulting change images. Generally, change images are compared to reference images, if they exist, resulting in an error matrix (Afify, 2011).

3.2.2 Classification Algorithms

In this study, Random Forest (RF) (Breiman, 2001), Support Vector Machines (SVM) (Hsu et al. 2016), and K-Nearest Neighbor (KNN) (Duda et al. 1973) machine learning (ML) algorithms were used for the classification of optical and SAR images. These classifiers are able to classify the input data by learning from the training data. Default parameters were used for all three algorithms. Only for RF, number of trees parameter was set to 10. Comparison table for these classifiers are given in Table 3.

Table 3. SVM, RF and KNN classifiers advantages/disadvantages (Thanh Noi and Kappas, 2017)

| Classifier | Advantage | Disadvantage |
|--|---|--|
| Support Vector Machine (SVM) | Insensitive to noise/overtraining | Less sensitive to training dataset size |
| Random Forest (RF) | Robust to noise in data. Insensitive to noise/overtraining | Size and imbalanced data of training samples has more impact on the classification accuracy |
| k-Nearest Neighbor (KNN) classifier | Adjusts to multi class problems without any extra efforts. | Ideal value for the k parameter is hard to set, if k is too small it may lead to overfitting |

Random Forest (RF)

RF algorithm is widely used in remote sensing applications. It is stable and efficient in runtime. RF combines many decision trees which are built during the training process. Training samples and variables are randomly selected. Each training sample is assigned to a class by using majority voting within these trees. The performance of the classifier is evaluated with samples not used in the training process. For each node, a random feature is selected from the feature set to split the tree properly. Generally, two parameters are used in RF: the number of trees and the number of nodes (Taheri Dehkordi et al. 2022; Amani et al. 2019).

Support Vector Machines (SVM)

SVM is a supervised ML method which is commonly used for regression and classification purposes. It is advantageous to use it when the sample size is small and in high dimensional feature space. SVM aims to find the optimal hyperplanes by using the training data to separate classes. Extreme vectors i.e. support vectors are selected to generate the hyperplanes. Kernel function type, gamma value, and cost value are the parameters of this algorithm. The linear kernel is used to project the input space to higher spaces when the data volume is high in order to separate the data (Taheri Dehkordi et al. 2022; Amani et al. 2019).

K-nearest Neighbor (KNN)

KNN is a non-parametric ML method that is commonly used for statistical applications. The algorithm finds the K-nearest samples to unknown samples by using the distance functions. The K value is the single parameter that can be defined by using bootstrap techniques (Thanh Noi and Kappas, 2017).

3.2.3 Accuracy Calculation

An error matrix is commonly used to calculate the accuracy of a classification. The degree of closeness of classification results to the values accepted as true is measured with accuracy term. Error matrix is used to determine overall accuracy consumer accuracy, producer accuracy and kappa statistics (Damtea et al. 2020). Overall Accuracy (OA) metric is in this study, classification accuracy has been calculated as the overall accuracy (OA) after validation and kappa coefficient (κ) (Cohen, 1960) was calculated by using the error matrix output of GEE for each classifier.

Kappa coefficient is a statistical measure which evaluates the agreement between training and validation. (κ) takes values in range $(-1,+1)$ and values greater than 0.5 implies that it is in good agreement with classification (Taati et al. 2015).

3.2.4 Spectral Index Analysis

Optical images which are nearest to the event day (as given in Table 1) were mostly covered with clouds. These image composites are given in Figure 4.




Figure 4. a) Sentinel-2 MSI before event image composite, b) Sentinel-2 MSI after event image

As seen in Figure 4, the image composite representing ‘before event’ dates have a high rate of cloud (left). The right image composite has a lower cloud rate but when Sentinel-1 SAR images have been examined it was seen that the cloudy area covers most of the flooded area. Because of that, change detection for optical images would not provide accurate evidences of flood. Spectral indice usage is an alternative to discriminate areas covered with water in an unsupervised manner. In order to discover flooded areas with spectral indices, NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), mNDWI (modified NDWI) and NDMI (Normalized Difference Moisture Index) were applied to Sentinel-2 MSI after event image. Formulas are given in Table 4.

Table 4. The spectral indices (Goffi et al. 2020)

| Index | Formula | Reference |
|--------------|-------------------------------------|-------------------|
| NDVI | $(NIR - RED) / (NIR + RED)$ | Rouse et al. 1974 |
| MNDWI | $(GREEN - SWIR1) / (GREEN + SWIR1)$ | Xu, 2006 |
| NDWI | $(GREEN - NIR) / (GREEN + NIR)$ | McFeeters, 1996 |
| NDMI | $(NIR - SWIR) / (NIR + SWIR)$ | Hardisky, 1983 |

None of the images composed by spectral indices given in Table 4 was helpful to discriminate land covered with water, even special indices for water identification (NDWI, MDNWI). This is mostly because of the cloud coverage in flooded areas. Output images of spectral indices are given in Figure 5.




Figure 5. a) Output images of spectral indices MNDWI, b) NDMI, c) NDVI and d) NDWI

As seen in Figure 5, four of the spectral indices of Sentinel-2 MSI image on 2021-02-06 provide very similar results. After visual checking of these images NDWI image was selected to use in class feature selection of non-water areas.

4. Results

4.1 Flood Maps as Outputs of SAR CD

Mosaicked and smoothed Sentinel-1 SAR images representing before and after flood event images for the ROI are given in Figure 6. In the VH band image, flooded areas can be seen more clearly in black color when compared to the VV band.




Figure 6. a) Before event VV SAR image, b) after event VV SAR image, c) before event VH image, d) after event VH image

In order to observe the changes, change detection was applied (after event minus before event) to mosaicked and smoothed SAR images for both VV and VH bands by taking their differences (Figure 7).




Figure 7. a) SAR difference image for VV band, b) SAR image for VH band

In Figure 7, it can be seen that the speckle effect in the image of VV band is higher than the image of VH band. The VH band image depicts the flood inundated areas more concisely.

4.2 Classification Using GEE

Mosaicked Sentinel-2 after event image was obtained from Sentinel-2 dataset with 'B2', 'B3', 'B4', 'B8', 'B11', 'B12' bands. For the training of supervised classifiers (KNN, SVM, and RF) this image was used as input with the feature collections given in Table 2 as class labels. Classified images for the three classifiers are given in Figure 8.

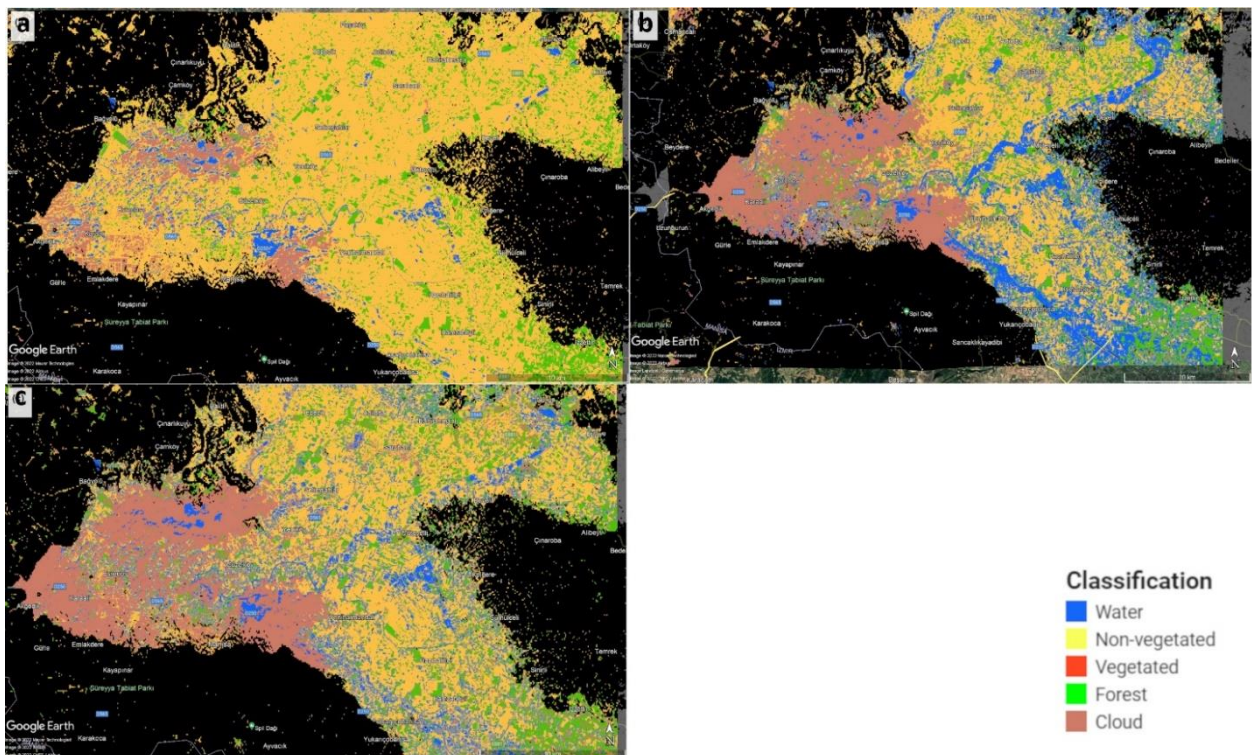


Figure 8. a) KNN classifier output, b) SVM classifier output, c) RF classifier output for Sentinel-2 MSI image composite

In Figure 8, areas classified as water can be seen in blue color. KNN classifier performs worst by depicting very small areas as clouds and water. It is a good practice to verify these results with a ground-truth image. For this purpose, inundated areas have been manually checked with the SAR difference images given in Figure 7.

It can be seen that the SVM classifier provides the most similar output to difference image in regard to the other classifiers while RF and KNN classifiers show a very speckled pattern. RF classifier shows flooded areas better than the KNN classifier but the resulting image is not satisfactory to reflect the flood inundation.

These classifiers were also applied to after flood event Sentinel-1 SAR image with the same steps applied for Sentinel-2 MSI image except for only two feature classes: water and other areas, as given in Table 2. Resulting classified outputs are given in Figure 9.

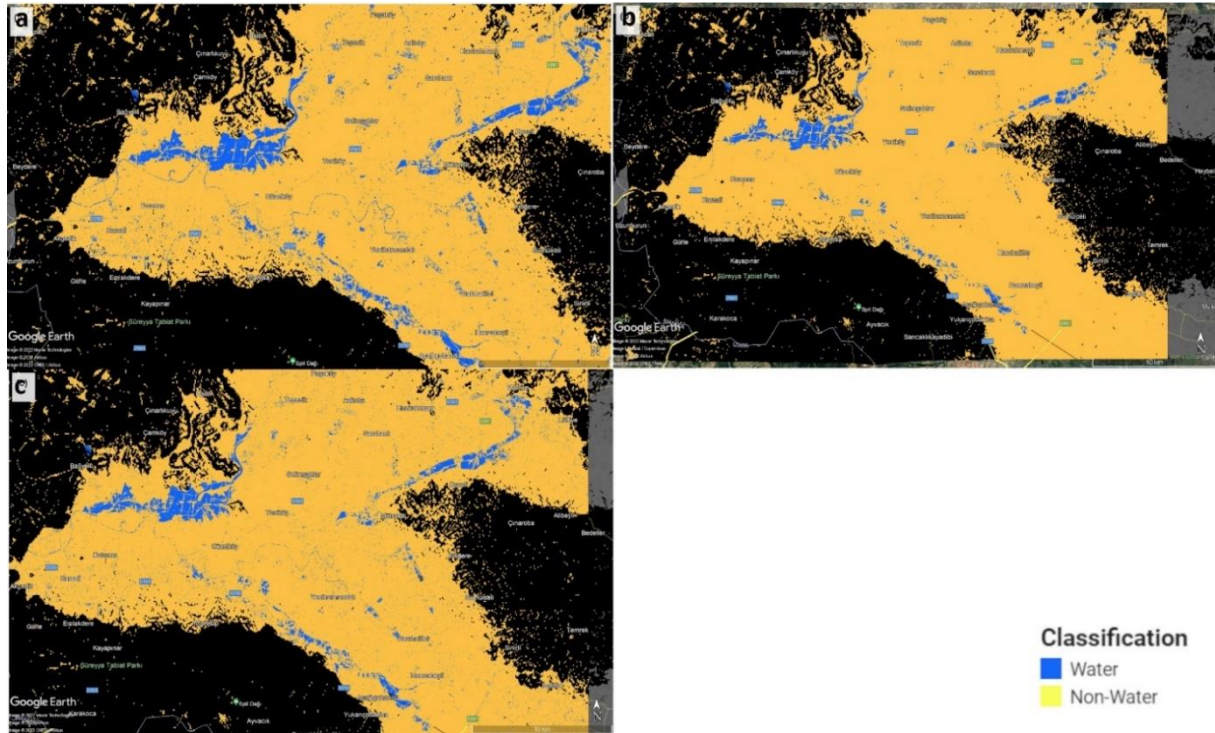


Figure 9. a) KNN classifier output, b) SVM classifier output, c) RF classifier output for Sentinel-1 SAR image

In Figure 9, areas classified as water are shown in blue color. All classifiers provide very similar outputs for flooded areas except KNN classifier predicts a wider area. When these images are checked with the SAR difference images given in Figure 7, it can be seen that flooded regions are discovered correctly by KNN classifier, but resulting in a scattered pattern.

4.3 Classification Results

Overall accuracy (OA) and Kappa coefficient values for each training/validation implementation of the three classifiers were calculated. In remote sensing, accuracy implies what proportion of the actual image was correctly predicted. The validation step was carried out to evaluate the trained model after the training processes were completed. In this step, validation data given in Table 2 was used. As said for training, validation OA was also calculated with corresponding kappa coefficient values for each classifier. Training and validation overall accuracy (OA) values of three classifiers for Sentinel-2 MSI and Sentinel-1 SAR data are given in Table 5 and Table 6, respectively.

Table 5. Training accuracy and Validation OA (%) values for Sentinel-2 MSI data

| Classifier | Training | Validation | Kappa |
|------------|----------|------------|-------|
| RF | 99.8 | 82.8 | 0.73 |
| KNN | 84.6 | 77.3 | 0.65 |
| SVM | 98.7 | 84.0 | 0.75 |

For Sentinel-2 MSI data, training accuracy values are high for both RF and SVM classifiers. SVM performs best with overall accuracy (validation) value of 84% kappa coefficient value 0.75 is substantial (>0.5) (Taati et al. 2015) as seen in

Table 5. RF classifier perform second best with OA value of 82.8% with kappa value of 0.73. KNN classifier performs worst with 77.3% OA value. Visual check comments given in Section 4.2 verify the numerical results given in Table 5.

Table 6. Training accuracy and Validation OA (%) values for Sentinel-1 SAR data

| Classifier | Training | Validation | Kappa |
|------------|----------|------------|-------|
| RF | 98.4 | 92.3 | 0.78 |
| KNN | 94.0 | 93.3 | 0.80 |
| SVM | 95.7 | 90.0 | 0.69 |

The same training and validation steps were applied to Sentinel-1 SAR after event image (VH). Differently, feature classes prepared for SAR image given in Table 2 were used for sampling. Two classes were enough to represent the image as water and other areas. When the OA results given in Table 6 are considered, it is obvious that, training and validation values are high for RF, KNN and SVM classifiers where all kappa values show good agreement (≤ 0.8). These results reflect the classifier outputs given in Figure 9 where KNN classifier provides the highest validation and kappa values, consistent with manual image interpretations.

5. Discussion and Conclusion

In this study, flood inundation mapping of an extensive part of the Gediz plain for a flood event that occurred on 02.02.2021 was presented. European Space Agency (ESA) provides Sentinel-1 SAR and Sentinel-2 multispectral images free of charge. Google Earth Engine (GEE) presents a free cloud service for high-performance computing in a bundle of Machine Learning (ML) algorithms and a large amount of satellite data for public use. We have taken advantage of cloud computing via GEE to map inundated areas in Gediz plain by examining the SAR images in a traditional change detection approach. Supervised classification was performed by using the built-in GEE ML algorithms: RF, KNN, and SVM.

SAR change detection images were used for validation of the supervised classification results because of the lack of ground truth for the study area on the event day. Results imply a major point in image classification with supervised classifiers. The point is the selection of the polygons for training and validation. RF and SVM gives very high training accuracy values as 99.8% and 98.7%, respectively. A large polygon set was composed for training in the study and these high values imply the sufficiency of this dataset. Also overfitting can be seen for SVM and RF classifiers in the lower right part of Figure 8.b when compared with the corresponding Sentinel-1 SAR imagery. When this region was investigated it has been observed that there does not exist any train and validation polygons in the right lower bound of the study area. This was done intentionally because the blue pixels in SWIR composite (Figure 2) regarding this region was not absolutely blue, conversely these regions were heterogeneous with a combination with some white, black, blue pixels. It would increase noise if these regions were labelled. This claim also supports the best OA values of RF and SVM classifiers. SVM performs best with overall accuracy value of 84% kappa coefficient value 0.75. SVM is advantageous in image classification problems where input/output dependencies are unknown. Regarding the noisy nature of the training dataset robustness of SVM classifier gives the best OA values among other classifiers.

Same classifiers were applied to Sentinel-1 SAR after event image with unique training and validation polygons. The best performing classifier for SAR image was KNN classifier with an OA value of 93.3% and a good kappa value 0.80. RF classifier performs very near to KNN classifier with an OA value of 92.3% and a good kappa value 0.78. This classification was implemented with two classes and noise in data is very low because of two pixel values: black or white. Although KNN and RF classifiers give near OA values, KNN classifier output is very similar to SAR difference images in Figure 7. RF classifier output should be very near to this result, the cause could be overfitting with a 98.4% training accuracy value.

During and after the heavy rainfall, Sentinel-2 MSI images were covered with clouds. Even though, after the event image cloud rate was low in rate, cloudy regions in the image affected the classifiers in a negative way by covering a large extent of the flooded area. Classifiers were trained with Sentinel-1 SAR and Sentinel-2 MSI images to acquire the best result. The best accuracy results were acquired by the SVM classifier for the optical and kNN classifier for the SAR after event images. It was hard challenging to hand label polygons in Sentinel-2 MSI images. To improve the results a large number of polygons were labelled. Results of the study verify the efficiency of SAR images in all-weather and their robustness to clouds.

Acknowledgement

This study is supported by Çukurova University Scientific Research Projects Coordination Unit under grant number: FBA-2021-14022.

References

- Afify, H. A. (2011). Evaluation of change detection techniques for monitoring land-cover changes: A case study in new Burg El-Arab area. *Alexandria Engineering Journal*, 50(2), 187-195.
- Amani, M., Brisco, B., Afshar, M., Mirmazloumi, S. M., Mahdavi, S., Mirzadeh, S. M. J., & Granger, J. (2019). A generalized supervised classification scheme to produce provincial wetland inventory maps: An application of Google Earth Engine for big geo data processing. *Big Earth Data*, 3(4), 378-394.
- Arslan, D., Çiçek, K., Döndüren, Ö., & Ernoul, L. (2021). Threat ranking to improve conservation planning: an example from the Gediz Delta, Turkey. *Land*, 10(12), 1381. doi: 10.3390/land10121381.
- Baghi, A., & Karami, A. (2017). SAR image segmentation using region growing and spectral cluster. In *3rd International Conference on Pattern Recognition and Image Analysis (IPRIA), 2017. Proceedings.* (pp. 229-232). IEEE.
- Benoudjit, A., & Guida, R. (2019). A novel fully automated mapping of the flood extent on SAR images using a supervised classifier. *Remote Sensing*, 11(7), 779. doi: 10.3390/rs11070779.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Brown, K. M., Hambidge, C. H., & Brownett, J. M. (2016). Progress in operational flood mapping using satellite synthetic aperture radar (SAR) and airborne light detection and ranging (LiDAR) data. *Progress in Physical Geography*, 40(2), 196-214.
- Cao, H., Zhang, H., Wang, C., & Zhang, B. (2019). Operational flood detection using Sentinel-1 SAR data over large areas. *Water*, 11(4), 786. doi: 10.3390/w11040786.
- Carincotte, C., Derrode, S., & Bourennane, S. (2006). Unsupervised change detection on SAR images using fuzzy hidden Markov chains. *IEEE Transactions on Geoscience and Remote Sensing*, 44(2), 432-441.
- Chang, Y. L., Anagaw, A., Chang, L., Wang, Y. C., Hsiao, C. Y., & Lee, W. H. (2019). Ship detection based on YOLOv2 for SAR imagery. *Remote Sensing*, 11(7), 786. doi: 10.3390/rs11070786.
- Chen, Y., Li, J., & Chen, A. (2021). Does high risk mean high loss: Evidence from flood disaster in southern China. *Science of The Total Environment*, 785, 147127. doi: 10.1016/j.scitotenv.2021.147127.
- Cian, F., Marconcini, M., Ceccato, P., & Giupponi, C. (2018). Flood depth estimation by means of high-resolution SAR images and lidar data. *Natural Hazards and Earth System Sciences*, 18(11), 3063-3084.
- Clement, M. A., Kilsby, C. G., & Moore, P. (2018). Multi-temporal synthetic aperture radar flood mapping using change detection. *Journal of Flood Risk Management*, 11(2), 152-168.
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46.
- Čotar, K., Oštir, K., & Kokalj, Ž. (2016). Radar satellite imagery and automatic detection of water bodies. *Geodetski glasnik*, 50(47), 5-15.
- ÇOB. (2007). *Gediz Deltası Sulak Alan Yönetim Planı*. Ankara: T.C. Çevre ve Orman Bakanlığı, Doğa Koruma ve Milli Parklar, Sulak Alanlar Şube Müdürlüğü.
- Damtea, W., Kim, D., & Im, S. (2020). Spatiotemporal analysis of land cover changes in the chemoga basin, Ethiopia, using Landsat and google earth images. *Sustainability*, 12(9), 3607. doi: 10.3390/su12093607.
- Duda, R. O., Hart, P. E., & Stork, D. G. (1973). *Pattern classification and scene analysis*. New York, NY: Wiley.
- Goffi, A., Stroppiana, D., Brivio, P. A., Bordogna, G., & Boschetti, M. (2020). Towards an automated approach to map flooded areas from Sentinel-2 MSI data and soft integration of water spectral features. *International Journal of Applied Earth Observation and Geoinformation*, 84, 101951. doi:10.1016/j.jag.2019.101951.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Hardisky, M.A., Klemas, V., & Smart, R. (1983). The influence of soil salinity, growth form, and leaf moisture on-the spectral radiance of Spartina alterniflora Canopies. *Photogrammetric Engineering and Remote Sensing*, 49(1), 77-83.
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2016). *A practical guide to support vector classification*. Retrieved from <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.
- Klemas, V. (2013). Remote sensing of emergent and submerged wetlands: An overview. *International Journal of Remote Sensing*, 34(18), 6286-6320.
- Kurita, T., Otsu, N., & Abdelmalek, N. (1992). Maximum likelihood thresholding based on population mixture models. *Pattern Recognition*, 25(10), 1231-1240.

- Martinis, S., Kuenzer, C., Wendleder, A., Huth, J., Twele, A., Roth, A., & Dech, S. (2015). Comparing four operational SAR-based water and flood detection approaches. *International Journal of Remote Sensing*, 36(13), 3519-3543.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432.
- MGM, (2023). *Resmi İstatistikler, İllere Ait Mevsim Normalleri (1991-2020)*. Retrieved from <https://mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=H&m=MANISA>.
- Ozkan, S. P., & Tarhan, C. (2016). Detection of flood hazard in urban areas using GIS: Izmir case. *Procedia Technology*, 22, 373-381.
- Pradhan, B., Hagemann, U., Tehrany, M. S., & Prechtel, N. (2014). An easy to use ArcMap based texture analysis program for extraction of flooded areas from TerraSAR-X satellite image. *Computers & Geosciences*, 63, 34-43.
- Pramanick, N., Acharyya, R., Mukherjee, S., Mukherjee, S., Pal, I., Mitra, D. & Mukhopadhyay, A. (2022). SAR based flood risk analysis: A case study Kerala flood 2018. *Advances in Space Research*, 69(4), 1915-1929.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. In *Third Earth Resources Technology Satellite-1 Symposium, 1974. Proceedings*. (pp. 309-317). NASA.
- Schumann, G., Di Baldassarre, G., Alsdorf, D., & Bates, P. D. (2010). Near real-time flood wave approximation on large rivers from space: Application to the River Po, Italy. *Water Resources Research*, 46(5), W05601. doi: 0.1029/2008WR007672.
- Solbø, S., & Solheim, I. (2005, September). Towards operational flood mapping with satellite SAR. In *Envisat & ERS Symposium, 2004. Proceedings*. (pp. 1-8).
- 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.
- Taheri Dehkordi, A., Valadan Zoej, M. J., Ghasemi, H., Ghaderpour, E., & Hassan, Q. K. (2022). A new clustering method to generate training samples for supervised monitoring of long-term water surface dynamics using Landsat data through Google Earth Engine. *Sustainability*, 14(13), 8046. doi: 10.3390/su14138046.
- Thanh Noi, P., & Kappas, M. (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 18(1), 18. doi: 10.3390/s18010018.
- Topouzelis, K. N. (2008). Oil spill detection by SAR images: dark formation detection, feature extraction and classification algorithms. *Sensors*, 8(10), 6642-6659.
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.

Kayseri’de Çoklu Regresyon ve Coğrafi Ağırlıklı Regresyon Yöntemleri ile Konutların Toplu Değerlemesi

Mass Appraisal of Residential Units in Kayseri with Multiple Regression and Geographically Weighted Regression Methods

Mehmet Fatih Toprak^{1*}, Oğuz Güngör²

¹Kayseri Büyükşehir Belediyesi, İmar ve Şehircilik Müdürlüğü, 38010, Kayseri/Türkiye.

²Ankara Üniversitesi, Uygulamalı Bilimler Fakültesi, 06590, Ankara/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Mehmet Fatih Toprak
mftoprak@kayseri.bel.tr

doi: 10.48123/rsgis.1255881

Yayın süreci

Geliş tarihi: 24.02.2023
Kabul tarihi: 03.03.2023
Basım tarihi: 28.03.2023

Özet

Konutların toplu olarak değerlendirme işlemleri için çoklu regresyon ve coğrafi ağırlıklı regresyon analizleri kullanılarak yürütülen bu çalışma için Kayseri’de çok katlı binalarda yer alan konut verileri toplanmıştır. Öznitelik bilgileri olarak, konutun çevresine, konutun içinde bulunduğu binaya ve konutun iç özelliklerine ilişkin bilgiler toplanmıştır. Toplam 1365 adet veri ile yürütülen çalışmada her iki yöntemle ilişkin sonuçların karşılaştırılabilmesi için R^2 , Ortalama Mutlak Hata (MAE), Mutlak Hata Oranları Ortalaması (MAPE), Hata Kareleri Ortalaması (MSE) ve Hata Kareleri Ortalamasının Karekökü (RMSE) ölçütleri hesaplanmıştır. Çoklu regresyon yönteminde R^2 : 0.741796, MAE: 89326, MAPE: 0.1675, MSE: 13256373049, RMSE: 115136 ve standart sapma: 0.1576 olarak bulunmuştur. Coğrafi ağırlıklı regresyon yönteminde ise R^2 : 0.762649, MAE: 85533, MAPE: 0.1604, MSE: 12185751976, RMSE: 110389 ve standart sapma: 0.1536 olarak hesaplanmıştır. Çoklu regresyon ve coğrafi ağırlıklı regresyon analizleri ile konut değer tahminlerinin her ikisinde de sonuçlar birbirine çok yakın çıkmış ve Kayseri şehir merkezinde konutların toplu olarak değerlendirme işlemlerinin bu yöntemlerle yapılabileceği sonucuna varılmıştır.

Anahtar kelimeler: Konut değerlendirme, Toplu değerlendirme, Çoklu regresyon, Coğrafi ağırlıklı regresyon

Abstract

For the purpose of mass appraisal, this study collected data on residential units located in multi-story buildings in Kayseri, and utilized multiple regression and geographically weighted regression analyses. Information on the surrounding area, the building in which the residential unit is located, and the interior features of the units were collected as attribute information. In the study, which was conducted with a total of 1365 data, R^2 , Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE) criteria were calculated to compare the results of both methods. In multiple regression analysis, R^2 was found to be 0.741796, MAE was 89326, MAPE was 0.1675, MSE was 13256373049, RMSE was 115136, and the standard deviation was 0.1576. In the geographically weighted regression analysis, R^2 was calculated as 0.762649, MAE was 85533, MAPE was 0.1604, MSE was 12185751976, RMSE was 110389, and the standard deviation was 0.1536. In both multiple regression and geographically weighted regression analyses, the results of estimated values were very close to each other, and it was concluded that mass appraisal processes of residential units in Kayseri city center can be performed with both methods.

Keywords: Residential units valuation, Mass appraisal, Multiple regression, Geographically weighted regression

1. Giriş

İnsanın sağlıklı bir yaşam sürdürebilmesinin temelini konut oluşturur ve bu nedenle Maslow'un ihtiyaçlar hiyerarşisinde konut önemli bir yere sahiptir. Konut, insanın en temel ihtiyaçlarının karşılandığı ve insanlığın devamının sağlandığı mekandır (Baran, 2007). İnsanların barınma ve korunma amacıyla kullandıkları mekanlar zaman içinde sosyal, kültürel, ekonomik, siyasal, hukuksal ve teknolojik boyutları olan bir yapıya dönüşmüştür. Sadece barınma değil, diğer bazı ihtiyaçlarının karşılanmasında da konut insan hayatı için vazgeçilmez bir unsur olmuştur (Demirci, 2009). Konutun özellikle ekonomik yönü itibarıyla, insan hayatında önemli bir yere sahip olması, değerinin belirlenmesi gereğini de ortaya çıkarmıştır.

İngilizcedeki karşılığı "Appraisal" veya "Valuation" olan gayrimenkulün değeri, bir gayrimenkule ilişkin faydalar, nitelik, çevre koşulları ve gayrimenkulün kullanımına ilişkin faktörler değerlendirilerek belirlenir (Tanrıvermiş, 2017). Değerlemede kullanılacak yöntemlerin seçiminde; değerlemenin amacı, malın cinsi ve özellikleri, yasal düzenlemeler ve piyasa koşulları gibi faktörler dikkate alınır. Bir veya daha fazla yöntem seçilerek değerlendirme yapmak mümkündür. Bu yöntemler genel hatlarıyla pazar, maliyet, gelir, karma ve diğer yöntemler olarak ele alınmıştır (Tanrıvermiş, 2017). Bununla birlikte Lisanslı Değerleme Uzmanları Kralliyet Kurumu (Royal Institution of Chartered Surveyors - RICS) otomatik değerlendirme yaklaşımlarına da değerlendirme standartları arasında yer vermiştir (İlhan ve Öz, 2020).

Taşınmazın konumu, fiziksel, ekonomik özellikleri, imar planlarındaki durumu, mülkiyet yapısı değerinin belirlenebilmesinde etkilidir. Sosyal donatı alanlarına ve kentsel hizmet alanlarına, alışveriş merkezlerine uzaklık ve kamusal hizmetlerden yararlanabilme olanakları da değer belirlenebilmesinde önem taşımaktadır (Tanrıvermiş, 2017). Ayrıca Demirel vd. (2018) konum, altyapı, nüfus, sosyoekonomik durum, ulaşım, bina ve daire özelliklerinin konutun değerini belirleyen ana başlıklar olarak ele almıştır.

Değerlemesi yapılacak konut bir tane olabileceği gibi birden fazla da olabilmektedir. Birden fazla taşınmazın değerinin hızlı ve güvenilir bir şekilde tespit edilebilmesi için belirlenen bir örneklem üzerinde istatistiksel yöntemler kullanılarak gerçekleştirilen değerlendirme işlemi toplu değerlendirme olarak tanımlanmaktadır. Başka bir deyişle toplu değerlendirme, bir grup gayrimenkulün piyasa değerini belirleyen matematiksel modelin istatistikler ve coğrafi bilgi sistemleri ile sunulmasıdır (Tanrıvermiş, 2017).

Toplu değerlendirme işlemleri için çoklu regresyon analizi, yapay sinir ağları gibi modern değerlendirme yöntemleri ve coğrafi bilgi sistemleri tabanlı konumsal analizlerin kullanıldığı da görülmektedir. Toplu olarak gayrimenkul değerlemesinin yapılması dünyanın birçok ülkesinin gündeminde olup tartışılan bir konudur. Bütün ülkelerde bu konuda geliştirilen yaklaşımlar farklı olabilmektedir, ancak ortak noktalar da bulunmaktadır. Örneğin, Avrupa Birliği ülkelerinde vergilendirme amaçlı toplu değerlendirme işlemleri hâkim olup, geliştirilen modeller genellikle çoklu regresyon analizine dayanan hedonik denklemler olmaktadır (İlhan ve Öz, 2020). Bu yaklaşımlardaki esasların veya toplu değerlemeye ilişkin usullerin belirlenmesinde, IAAO gibi seminerler veya uluslararası konferansların sonuçlarından yararlanılmaktadır (Walacik vd. 2013). Toplu değerlemelerin uygulandığı birçok ülkede bu sürecin öncelikle vergilendirme amaçlı kullanıldığı ve yönetsel olarak farklı kurumların sorumluluk alanlarına girdiği görülmektedir. Toplu değerlemeye ilişkin yayımlanmış standartlar bulunmasına rağmen, ülkelerde özellikle veri toplama ve veri kayıt sistemlerinin farklılaşmasından ötürü farklı modeller uygulanmaktadır.

Modern değerlendirme yöntemleri de toplu değerlendirme yöntemleri arasında sayılmaktadır. Khamrabaeva (2020)'ya göre modern değerlendirme yöntemleri, modern olmayan diğer yöntemlerin eksikliklerini gidermek için oluşturulmuş biraz daha gelişmiş tekniklerdir. Modern değerlendirme yöntemleri zor olmakta birlikte, analizi, yorumlanması, uzman görüşü gerektirmesi ve teknolojik bilgi istemesinin yanı sıra, gerçek değerlerin tahmin edilmesinde hata oranı en az olan tekniklerdir. Modern değerlendirme yöntemleri sayesinde çok sayıda verinin işlenmesi ile bir sonuca ulaşılabilir. Gayrimenkul değeri belirlenirken diğer yöntemlere göre daha fazla zaman almakta olan bu yöntemlerde, bilgisayar programları yardımı ile verilerin detaylı analizi yapılarak, bu analiz sürecinde hata oranının en az olması hedeflenmektedir (Khamrabaeva, 2020).

"Gelişmiş Değerleme Yöntemleri" başlığı altında Odabaşı (2020) bilgisayar sistemlerine dayalı değerlendirme yöntemlerini ele almıştır. Bilgisayar sistemleri ile yapılan değerlendirme işlemleri Khamrabaeva (2020)'nin "Modern Değerleme Yöntemleri" başlığıyla örtüşmektedir.

Yalprı (2007) bilgisayar teknolojisinin insan yaşamının her alanında olduğuna, bilgisayar teknolojilerine dayalı değerlendirme işlemlerinin yapılabileceğine ve çok fazla sayıda verinin işlenerek detaylı analizlerin gerçekleştirilebileceğine vurgu yapmıştır.

Otomatik olarak yapılan bir değerlendirme işleminin başarısını değerlendirmek için yaygın olarak kullanılan ölçütler Mutlak Hata Oranları Ortalaması (MAPE), Hata Kareleri Ortalaması (MSE) ve Hata Kareleri Ortalamasının Karekökü (RMSE) olup formüller şu şekildedir:

$$MAPE = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (1)$$

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad (2)$$

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (3)$$

$$MAE = \frac{\sum_{t=1}^n |u_t|}{n} \quad (4)$$

Bu eşitliklerde y_i ölçüm değerlerini, \hat{y}_i tahmin değerlerini, u_t ölçüm ve tahmin değerleri arasındaki farkı ve n örnek sayısını ifade eder. MAPE, tahmin hatalarını yüzdesel olarak veren bir ölçüttür. RMSE, ölçüm değerleri ile tahmin değerleri arasındaki hatanın belirlenmesi için kullanılır. Bu değer in sıfıra yaklaşması modelin tahmin gücünün arttığını gösterir. MSE ise RMSE'nin karesine eşit olan En Küçük Kareler (EKK) yönteminin temel prensibine dayanan ve kestirimlerin başarılarını ölçmekte kullanılan diğer bir kriterdir. Karelerinin ortalaması ne kadar küçük ise model gerçek veriye o kadar yakındır. Ayrıca, Ortalama Mutlak Hata (MAE) da ağırlıklı doğruluğunu belirlemede bir ölçüt olarak kullanılabilen hata miktarlarının ortalamasıdır.

Diğer yandan yukarıdaki eşitlikler dışında ağırlıklı doğruluk oranına, R^2 belirleme katsayısı veya değişkenler arasındaki korelasyonu ifade eden R değeri ile de karar verilmektedir (İlhan ve Öz, 2020).

2. Çoklu Regresyon ve Coğrafi Ağırlıklı Regresyon

Literatürde basit doğrusal regresyon ve çoklu regresyon olmak üzere iki çeşit regresyon yönteminden bahsedilmektedir. Çoklu regresyon analizinde bağımsız ve bağımlı değişkenler işleme sokulur. Bağımlı değişken sayısı tektir ancak bağımsız değişken sayısı birden fazla olabilir. Tek bir bağımsız değişken varsa buna basit doğrusal regresyon, iki veya daha fazla bağımsız değişken varsa buna çoklu doğrusal regresyon denir. Regresyon analizi, değişkenler arasındaki ilişkiyi işlevsel anlam vermeyi ve bu ilişkiyi bir modelle açıklamayı amaçlar (Chatterjee vd. 2015). Değişkenlerden birini veya değişkenin kategorisini önceden belirlenmiş düzeylerde tutma ve diğer değişkenin o düzeye göre nasıl değiştiğini inceleme kuralına dayanır. Regresyon, modern istatistiklerde bilinen değerleri kullanarak bilinmeyen değerleri bulmak olarak da yorumlanmaktadır (Akış, 2013). Çoklu regresyon eşitliğinde y bağımlı değişkeni, a sabit katsayısı, $x_{1...n}$ bağımsız değişkenleri ve $\beta_{1...n}$ her bağımsız değişkenin katsayısını ifade eder.

$$y = a + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (5)$$

Türkiye'de konut değerlendirme çalışmalarında çoklu regresyon yönteminin kullanıldığı örnek çalışmalar mevcuttur. Konut değerinin çoklu regresyon ve yapay sinir ağları yöntemi ile karşılaştırmalı olarak tahmin edilmesine yönelik olarak çalışma yapan Tabar vd. (2021) Tokat ilinde toplam 176 adet veriye ilişkin, alan, oda sayısı, bina yaşı, kat, konum, banyo sayısı, balkon ve fiyat bilgilerini içeren bir veri seti ile çalışmıştır. İl merkezinde sadece bir mahalledeki konutlara ait özelliklerin ve değer aralıklarının birbirine benzer homojen denebilecek bir yapıda olması başarıyı artırmış, çoklu regresyon yöntemi ile %90'ın üzerinde bir başarı sonucuna ulaşıldığı görülmüştür. Çoklu regresyon yöntemi ile konut fiyat tahmini çalışmalarından biri de Küçükkaplan ve Aldı (2017) tarafından Denizli'de yapılmıştır. Bu çalışmada konutların buldukları mahallelerin konutun değerini ne kadar açıklayabildiğini araştırmak temel amaç olmuştur. Çalışmada oluşturulan modelin değer bağımsız değişkenini %73,70 oranında açıklayabildiği ifade edilmiştir.

Ayrıca, verilerin coğrafi konumlarının da bağımlı değişkeni olumlu veya olumsuz yönde açıklayıcı etkisinin olduğu varsayımı ile çalışan ve bir coğrafi bilgi sistemi ürünü olan coğrafi ağırlıklı regresyonun kullanımı da yaygındır. Verilerin elde edildiği coğrafi birimler tamamen birbirlerinden ayrı olarak düşünülemez. Olumlu ya da olumsuz, az ya da çok birbirleri ile ilişkilidirler. Tobler (1970) "Her şey her şeyle ilişkilidir, fakat yakındakiler uzaktakilere göre daha fazla ilişkilidir" ifadesiyle aslında coğrafi ağırlıklı regresyon kavramını işaret etmiştir. Bu yöntemle, bir veri noktası seçilir ve diğer noktalar bu noktadaki regresyon değerine göre, uzaklıkla ters orantılı olarak ağırlıklandırılır. Bu işlem tüm veri noktaları için gerçekleştirilir ve sonuçlar bu değerlere göre oluşturulur (Işık ve Pınarcıoğlu, 2006). Bu sayede, coğrafi birimlerin analiz sonucunda sahip oldukları regresyon değerleri birbirleri ile ilişkilendirilerek ağırlıklandırılır ve coğrafi ağırlıklı regresyon sonucu elde edilir. Coğrafi ağırlıklı regresyon sonucunda elde edilen eşitlik çoklu regresyon eşitliği ile benzerdir.

Otomatik konut değerlendirme çalışmalarından biri de Boza (2015) tarafından Ankara'nın Çankaya ve Keçiören ilçelerinde mekânsal olan ve mekânsal olmayan yöntemlerle yaptığı araştırmadır. Yöntemlerin başarısını tespit etmek için tahminlerin değerden olan uzaklığının gösterildiği regresyon doğrusuna olan uzaklığının ve istatistiksel olarak hata miktarlarının (MSE, RMSE, MAPE ve MAE) hesaplamalarını yapmıştır. Eşzamanlı mekânsal otoregresyon (Simultaneous Spatial Autoregression- SAR) ve coğrafi ağırlıklı regresyon yöntemlerinin mekânsal olmayan en küçük kareler yöntemine göre daha iyi sonuç verdiği belirtilmiştir. Coğrafi ağırlıklı regresyon ile elde edilen sonuçların harita üzerinde gösterilmesi, mekânsal özellikli verilerin değerlendirme işlemleri için önemli bir araç olduğunu ortaya çıkarmıştır. Konut alanı, güvenlik ve alışveriş merkezine uzaklık bilgilerinin hem Çankaya hem de Keçiören için ortak önemli faktörler olduğu ortaya çıkarken, Çankaya için mülkiyet tipi ve metroya uzaklık ve Keçiören için ise dairenin bulunduğu kat ve hane halkı değişkenleri konut değerine etki eden diğer önemli faktörler olmuştur.

McCord vd. (2018) Kuzey İrlanda'da özellikle hava kalitesi ve gürültü kirliliğinin konut değerleri üzerindeki etkisini araştırmak için coğrafi ağırlıklı regresyon ve en küçük kareler yöntemlerini kullanmışlardır. Hava kalitesinin ev değeri üzerinde etkisinin olduğunu, buna karşın gürültü kaynağının çeşidine göre, gürültü kirliliğinin evin değerine etki ettiği ve etki etmediği durumların da olduğu sonucuna varmıştır.

Toplu Değerleme için otomatik yöntem kullanımına Türkiye dışından bir başka örnek ise, 1997 ve 2002 yılları arasında satışı gerçekleşen, 1691 adet konutun fiyatlarını etkileyen faktörleri belirlemek için Osland (2010) tarafından coğrafi ağırlıklı regresyon, yarı parametrik analiz ve karma konumsal durbin modelinin kullanılmasıdır. Bu çalışmanın coğrafi ağırlıklı regresyon sonuçlarının değerlendirildiği kısmında, değişkenlerin sayısının ve hangi değişkenlerin modele dâhil edildiğine bağlı olarak, ulaşılan tahmin sonuçlarının değiştiğinden ve hatta değişkenlerin sırasının değiştirilmesinin bile sonucu etkilediğinden bahsedilmiştir. Sonuç olarak Osland (2010), coğrafi ağırlıklı regresyonun çoklu ilişkilerde hassas olduğunu, ama buna rağmen çoklu regresyondan çok daha iyi bir sonuç üretmediğini belirtmektedir.

Wang vd. (2020), Çin'in Pekin şehrinin ana merkezi sayılabilecek bir alanda, çoklu regresyon, coğrafi ağırlıklı regresyon ve coğrafi zamansal ağırlıklı regresyon (Geographically and Temporally Weighted Regression - GTWR) yöntemlerini kullanarak otomatik değerlendirme çalışma sonuçlarını karşılaştırmıştır. Coğrafi zamansal ağırlıklı regresyon yöntemi zaman serileri ve mekânsal dağılım özelliklerine sahip veri kümeleri için iyi analitik yeteneklere sahiptir. Bu çalışmada 3064 adet veri kullanılmıştır. Elde edilen R² sonuçları çoklu regresyonda 0.5679, coğrafi ağırlıklı regresyonda 0.2214 ve coğrafi zamansal ağırlıklı regresyonda ise 0.82 olmuştur. Coğrafi ağırlıklı regresyonun, zamansal ve mekânsal özellikleri içeren coğrafi zamansal ağırlıklı regresyona ve çoklu regresyona göre daha kötü sonuç vermiş olması dikkate değerdir. Coğrafi ağırlıklı regresyonun konum bileşenini de hesaba katıyor olması nedeniyle, çoklu regresyona göre daha iyi sonuç vermesi beklenebilirdi.

Lockwood ve Rossini (2012) toplu değerlendirme işlemi için, doğrusal model, log-lineer model, hibrit model ve coğrafi ağırlıklı regresyon olmak üzere 4 farklı model kullanmış ve sonuçlarını karşılaştırmıştır. Model performanslarını hesaplamak için kullanılan veriler müstakil evler ve boş arsalar olmuştur. Buna göre doğrusal modelde R² değeri 0.815 olurken, değişkenler arasında yüksek korelasyon olduğu tespit edilmiştir. Log-lineer model sonuçları ise sanki doğrusal model sonuçlarının aynadaki yansıması gibi neredeyse aynı çıkmıştır. Hibrit model sonuçlarına bakıldığında, biri hariç tüm değişken tahminlerinin %95'in üzerinde bir güven aralığında anlamlı olduğu görülmüştür. Coğrafi ağırlıklı regresyon yönteminde kukla değişken kullanılmış ancak R² veya başkaca bir ölçüte ait sonuca açıkça yer verilmemiştir.

3. Kayseri İlinde Doğrusal Regresyon ve Coğrafi Ağırlıklı Regresyon ile Konut Değerleme Çalışması

Bu çalışmanın yürütülme aşamaları; konutun değerini belirleyen muhtemel değişkenlerin literatürdeki çalışmalara bakarak eldeki imkânlar ölçüsünde hangi değişkenlerin toplanabileceğinin belirlenmesi, verilerin toplanması, toplanan verilere ait değişkenlerin veri tabanına girilmesi, hesaplanması gereken değişkenlerin otomatik olarak hesaplanması (calculate), aykırı verilerin (outliers) temizlenmesi, çoklu regresyon ve coğrafi ağırlıklı regresyon analizlerinin yapılması, belirlenen ölçütlerin hesaplanması, elde edilen sonuçların değerlendirilmesi ve son olarak karşılaştırılması şeklinde olmuştur.

Bilgisayar yazılımı destekli değerlendirme yöntemleri sayesinde öznitelik temelli, hızlı bir şekilde çok büyük veri kümelerinin işlenebilmesi mümkün olabilmektedir. Çoklu regresyon ve coğrafi ağırlıklı regresyon bu yöntemlerdendir. Bu çalışmada Kayseri ili özelinde konut değerlemesinin çoklu regresyon ve coğrafi ağırlıklı regresyon kullanılarak yapılabileceği ve yapılabiliyorsa ne oranda tutarlı sonuçlar elde edilebileceği yönünde araştırma yaparak, bir bulguya ulaşmak amaçlanmıştır.

Gayrimenkul konut, ofis, tarla vs. şeklinde sınıflandırılabilir. Konut dışındaki gayrimenkul türleri konuttan farklı öznitelik bilgilerine sahip oldukları için, her türden gayrimenkul için uygulanabilir bir otomatik değerlendirme mimarisi geliştirmek mümkün değildir. Bu nedenle, bütün gayrimenkul türleri için analizler yapmak yerine, sadece konut türündeki gayrimenkul için değer tahminlerinin yapılması tercih edilmiştir.

3.1 Veri Seti

Değerleme bilimine göre konutun değerini etkileyen faktörler doğrultusunda, her bir konuta ilişkin öznelik verileri toplanmıştır. İyi bir otomatik değerlendirme mimarisinin belirlenmesinde hangi öznelik bilgisinin konutun değerini ne oranda etkileyeceği konusunun, otomatik değerlendirme yöntemi geliştirilmeden önce bilinmesi mümkün olmadığından, her bir konuta ilişkin mümkün olduğunca fazla sayıda öznelik bilgisi toplanmaya çalışılmıştır.

Konutlara ilişkin verilerin toplanmasında internette yayınlanan konut satışı ilanlarından faydalanılmıştır. Her bir ilanın yayını esnasında öznelik bilgileri tespit edilip, *postgresql* veri tabanına kaydedilmiştir. Öznelik bilgilerinden binanın toplam kat adedi, bina yaşı, yolcu asansörü, yük asansörü, bina görevlisi, açık otopark, güvenlik, havuz, rezidans hizmetlerinden faydalanma, semt otoparkı, sığınak, site özellikleri, binada dükkan olup olmadığı, kapalı otopark, brüt alan, net alan, oda sayısı, salon sayısı, sıcak su, balkon, ebeveyn banyosu, kiler ve stüdyo tipi daire olup olmadığı bilgileri ilandan edinilirken, ulaşım imkanları, alışveriş merkezine, ilkokula, taksi durağına, sağlık tesisine ve şehir merkezine yakınlık bilgileri, *postgis* özellikli coğrafi bilgi sistemi teknolojisi marifeti ile kuş uçuşu mesafeler olacak şekilde hesaplanmıştır. Konut ilanının yayından kaldırılması konutun satışının gerçekleştiğinin bir göstergesi kabul edilerek, konutun gerçek satış değerine ulaşmak adına ilan sahibine ulaşılmaya çalışılmıştır. İlan sahibi ile yapılan yazılı veya sözlü görüşmenin olumlu geçmesi halinde gerçek satış değeri bilgisine ulaşmak mümkün olabilmektedir. Aksi durumlara karşılaşılabildiğinde, uzman görüşüne başvurularak oluşturulan değer bilgisi, ileride başkaca çalışma ve yöntemler kapsamında bu verilerin de kullanılabilmesi ihtimaline binaen kayıtlara geçirilmiş, ancak bu çalışma kapsamında, aykırı ve eksik verilerin işlem dışı bırakıldığı aşamada bu tip veriler de yok sayılmıştır. Dolayısıyla, toplanan verilerden toplu değerlendirme çalışmasına temel teşkil etmeyeceği düşünülen; eksik veya doğruluğu şüpheli öznelik bilgileri içeren veriler ayıklanmış, daha güvenilir nitelikte 1365 adet konuta ait öznelik bilgilerinden oluşan bir veri seti oluşturulmuştur. Veri setinde 2022 yılının ocak ayında 45, şubat ayında 314, mart ayında 838 ve Nisan ayında 168 adet satış gerçekleşmiş konut verisi bulunmaktadır. Farklı zaman dilimlerinde toplanan bütün veriler Türkiye Cumhuriyet Merkez Bankası'nın yayınladığı konut fiyat endeksi ile 2022 yılının ocak ayına indirgenerek normalize edilmiştir (TCMB, 2022).

Konutun; Tablo 1'de gösterildiği üzere; ulaşım imkânları, alışveriş merkezine, ilkokula, taksi durağına, sağlık tesisine ve şehir merkezine yakınlığı, çevresel özellikler olarak belirlenmiştir. Binaya ilişkin ise; binanın toplam kat adedi, bina yaşı, yolcu asansörü, yük asansörü, bina görevlisi, açık otopark, güvenlik, havuz, rezidans hizmetlerinden faydalanma, semt otoparkı, sığınak, site özellikleri, binada dükkan ve kapalı otoparkın olup olmadığı bilgileri veri setinde yer almaktadır. Konutun iç özelliklerine dair; brüt alan, net alan, oda sayısı, salon sayısı, sıcak su, balkon, ebeveyn banyosu, kiler ve stüdyo tipi daire olup olmadığı bilgileri toplanmıştır.

Tablo 1. Değişken listesi

| Değişken no | Konuta ilişkin özellik kategorisi | Değişken kodu | Değişken adı | Değişken türü |
|-------------|-----------------------------------|-------------------------|------------------------------------|---------------|
| 1 | Çevresel özellikler | d9_ulasim | Ulaşım imkanları | Numerik |
| 2 | | d38_avm | Alışveriş merkezine yakınlık | Numerik |
| 3 | | d39_ilkokul | İlkokula yakınlık | Numerik |
| 4 | | d40_taksi | Taksi durağına yakınlık | Numerik |
| 5 | | d41_saglik | Sağlık tesisine yakınlık | Numerik |
| 6 | | d42_merkez | Şehir merkezine yakınlık | Numerik |
| 7 | Binaya ait özellikler | d13_katbina | Binanın toplam kat adedi | Numerik |
| 8 | | d14_binayasi | Bina yaşı | Numerik |
| 9 | | d10_asansoryolcuvariyok | Yolcu asansörü | Kategorik |
| 10 | | d11_asansoryukvariyok | Yük asansörü | Kategorik |
| 11 | | d12_binagorevliivariyok | Bina görevlisi | Kategorik |
| 12 | | d15_otoparkacikvariyok | Açık otopark | Kategorik |
| 13 | | d17_guvenlikvariyok | Güvenlik | Kategorik |
| 14 | | d18_havuzvariyok | Havuz | Kategorik |
| 15 | | d20_rezidanssevethayir | Rezidans hizmetlerinden faydalanma | Kategorik |
| 16 | | d21_otoparksemt | Semt otoparkı yeterli mi | Kategorik |
| 17 | | d23_siginakvariyok | Sığınak | Kategorik |
| 18 | | d24_siteevethayir | Site özellikleri | Kategorik |
| 19 | | d46_dukkanvarmivariyok | Binada dükkan olup olmadığı | Kategorik |

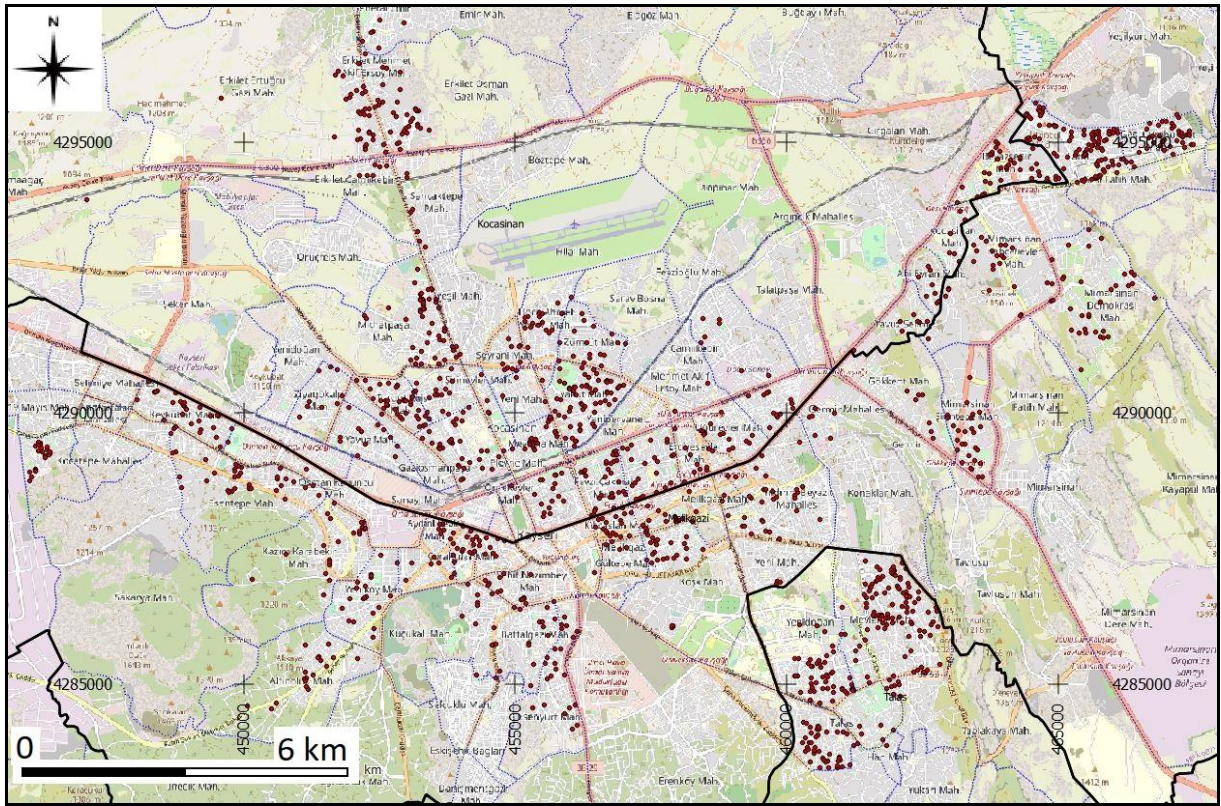
Tablo 1'in devamı

| Değişken no | Konuta ilişkin özellik kategorisi | Değişken kodu | Değişken adı | Değişken türü |
|-------------|--|-------------------------|-------------------|---------------|
| 20 | | d65_otoparkkapalivaryok | Kapalı otopark | Kategorik |
| 21 | Konutun iç özellikleri | d28_alanbrut | Brüt alan | Nümerik |
| 22 | | d64_alannet | Net alan | Nümerik |
| 23 | | d33_odasayi | Oda sayısı | Nümerik |
| 24 | | d34_salonsayi | Salon sayısı | Nümerik |
| 25 | | d22_sicaksuvar yok | Sıcak su | Kategorik |
| 26 | | d29_balkonvar yok | Balkon | Kategorik |
| 27 | | d30_banyoebeveynvar yok | Ebeveyn banyosu | Kategorik |
| 28 | | d32_kilervar yok | Kiler | Kategorik |
| 29 | | d35_studyoevethayir | Stüdyo tipi daire | Kategorik |
| 30 | | Bağımlı değişken | deger | Değer |
| 31 | Yazılım gereksinimleri için kullanılan değişkenler | id | Veri Numarası | Nümerik |
| 32 | | geom | Geometri | Nümerik |

Ayrıca, kullanılan yazılımın gereksinimlerini karşılamak üzere, verinin X ve Y koordinatlarını içeren geometri değişkeni ve veri numarası da veri setinde bulunmaktadır. Buna ek olarak, veri seti numerik olmayan, kategorik tipte değişkenler de içerdiği için, kukla değişkenli bir yapıya dönüştürülerek çalışmalar yürütülmüştür.

3.2 Çalışma Alanı

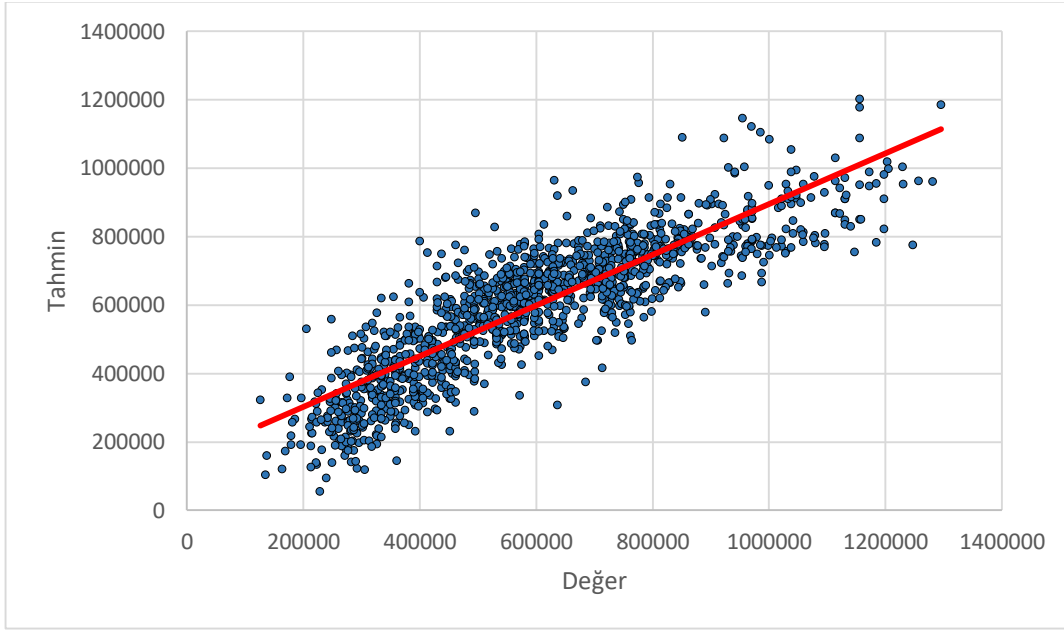
Çalışma Kayseri ilinin merkezinde yer alan Kocasinan, Melikgazi ve Talas ilçelerinde, konut satışlarının en yoğun olduğu yaklaşık 113 km²'lik bir bölgede, 69 mahallede yürütülmüştür. 1365 adet verinin mekânsal dağılımı Şekil 1'de gösterilirken, satış değerleri bakımından ısı haritası ise Şekil 2'de gösterilmiştir.




Şekil 1. Çalışma alanında verilerin konumsal gösterimi

Coğrafi ağırlıklı regresyon yönteminde her bölge için model katsayılarını hesaplayabilmek, çoklu regresyon yönteminde olduğundan daha büyük bir örneklem kümesini gerektirebilir. Buna ek olarak, çok büyük karmaşık veri kümeleri ile çalışırken işlem yoğunluğu fazla olabilir. Kayseri'deki bu çalışma kapsamında, çoklu regresyon yöntemi ile değer tahmini yapmak için, örneğin shape (*.shp) formatındaki mekânsal içerikli verileri de okuyup işleyebilme yeteneği olan, Spatial Analysis in Macroecology (SAM) programı kullanılmıştır.

Toplam 29 adet değişken kullanılarak gerçekleştirilen çoklu regresyon çalışması ile R^2 : 0.741796, MAE: 89326, MAPE: 0.1675, MSE: 13256373049, RMSE: 115136 ve standart sapma: 0.1576 olarak hesaplanmıştır. Bir konuta ait ortalama 89326 TL eksik veya fazla hata ile değer tahmininde bulunulabilmiş ve ortalama mutlak hata olarak ise %16.75 kadar yaklaşık sonuç ile değer tahmini yapılabilmektedir. 0.74 olan R^2 değeri, veri ve çoklu regresyon tahmininin uyum derecesini göstermektedir. Şekil 3'te gerçek değerler yatay eksende gösterilirken, tahmin edilen değerler dikey eksende gösterilmiştir. Tahmin ile değer arasındaki farklar ise Şekil 4'te gösterilmiştir.




Şekil 3. Çoklu regresyon yöntemi ile değer ve tahminlerin dağılım grafiği



Şekil 4. Çoklu regresyon ile değer ve farkların gösterimi

Çoklu regresyon yöntemi ile bağımlı değişkeni, bağımsız değişkenlerin ne kadar açıklayabildikleri belirlenmiştir. Ulaşım imkanları, ilkokula, taksi durağına yakınlık, binanın kat adedi, dairenin brüt alanı, oda sayısı, yolcu asansörü, bina görevlisi, açık otopark, güvenlik, sıcak su, site özellikleri, balkon, ebeveyn banyosu, kiler, binada dükkan olması ve kapalı otopark değişkenleri, gerçekleşen satış değerini pozitif yönde açıklayıcı niteliğe sahip iken; alışveriş merkezine, sağlık tesisine, şehir merkezine yakınlık, bina yaşı, konutun net alanı, salon sayısı, yük asansörü, havuz, rezidans, semt otoparkının yeterliliği, sığınak ve konutun stüdyo tipi daire olup olmaması değişkenleri değer bağımlı değişkenini negatif yönde etkilemektedir. Bağımsız değişkenler içerisinde dairenin brüt alanı ve oda sayısı değer değişkenini pozitif yönde en çok etkileyen özellikler iken; bina yaşı, şehir merkezine ve alışveriş merkezine yakınlık ise değer değişkenini negatif yönde etkileyen değişkenler olmuştur.

Yine aynı veri seti üzerinde coğrafi ağırlıklı regresyon ile değer tahmini yapılmıştır. Bu yöntem ile yapılan tahminlerde çoklu regresyon yönteminde olduğu gibi aynı ölçütlerin hesaplaması yapılmıştır. Coğrafi ağırlıklı regresyon işlemi yapmak için Semiparametric GWR/GWL modelling tool (GWR4) paket programı kullanılmıştır. Adı geçen bu program çok bilinen coğrafi bilgi sistemi programlarına göre daha istikrarlı ve çok daha çeşitli veri formatları ile çalışabilmektedir. Çoğu yazılımda veri setinin normalize edilmesi, diğer bir deyişle değişkenlere 0 ve 1 arasında bir değer verilmesi işlemi manuel olarak önceden yapılmalı iken, GWR4 programı bu işlemi yapan bir algoritmaya da sahiptir. Buna ek olarak GWR4 programı shape formatındaki verilerin yanı sıra .csv, .dbf, .dat vb. formatlardaki verileri, format dönüşümü uygulamadan, doğrudan coğrafi ağırlıklı regresyon analizine tabi tutabilmektedir. Bu tespitler, çalışma kapsamında tecrübe edilerek ortaya çıkarılmıştır. GWR4 programı ile yürütülen coğrafi ağırlıklı regresyon işlemi sonucunda değer ve tahminlerin dağılım grafiği Şekil 5'te gösterilmiştir.




Şekil 5. Coğrafi ağırlıklı regresyon yöntemi ile değer ve tahminlerin dağılım grafiği

İşlem sonucunda R^2 : 0.762649, MAE: 85533, MAPE: 0.1604, MSE: 12185751976, RMSE: 110389 ve standart sapma: 0.1536 olarak hesaplanmıştır.

Coğrafi ağırlıklı regresyon yöntemi ile yapılan tahmin işlemi, çoklu regresyon yöntemi kriterlerine ek olarak konum kriterini de içerdiği için literatürdeki bazı örneklerde olduğu gibi daha iyi bir sonuç vermesi beklenebilir. Coğrafi ağırlıklı regresyon yönteminde ortalama mutlak hata 85533 TL hesaplanmış olup, bu değer çoklu regresyon yönteminde 89326 TL olmuştur.

Coğrafi ağırlıklı regresyon yöntemi ile bağımlı değişkeni, bağımsız değişkenlerin ne kadar açıklayabildikleri de belirlenmiştir. Buna göre; ulaşım imkanları, ilkokula yakınlık, binanın kat sayısı, konutun brüt alanı, oda sayısı, yolcu asansörü, bina görevlisi, binanın açık otoparkı, güvenliği, sıcak su, sığınak, site, balkon, ebeveyn banyosu, kiler, stüdyo, binada dükkan ve kapalı otoparkın olması konutun değerini pozitif yönde etkilerken; alışveriş merkezine, taksi durağına, sağlık tesisine, şehir merkezine yakınlık, bina yaşı, net alan, salon sayısı, yük asansörü, havuz ve rezidans hizmetlerinin varlığı değeri negatif yönde etkilemektedir. Değeri pozitif yönde en çok brüt alan ve oda sayısı etkilerken; negatif yönde en çok bina yaşı ve alışveriş merkezine yakınlık etkilemektedir.



Şekil 6. Coğrafi ağırlıklı regresyon yöntemi değer ve farkların gösterimi

5. Sonuç ve Değerlendirme

Bu çalışmada çoklu regresyon ve coğrafi ağırlıklı regresyon yöntemleri birbirlerine yakın doğruluk değerleri vermiş, fakat çoklu regresyon yöntemi ile elde edilen hata miktarı (R^2 : 0.741796, MAE: 89326, MAPE: 0.1675, MSE: 13256373049, RMSE: 115136 ve standart sapma: 0.1576) coğrafi regresyon ile hesaplanan hata miktarından (R^2 : 0.762649, MAE: 85533, MAPE: 0.1604, MSE: 12185751976, RMSE: 110389 ve standart sapma: 0.1536) az da olsa yüksek çıkmıştır. Elde edilen sonuçlar veri setindeki veriler ile doğrudan alakalıdır. 69 farklı mahalleden toplanmış ve bu nedenle dağınık konumlarda, değer aralığı çok geniş ve sayı bakımından da oldukça fazla sayılabilecek bir miktar olan 1365 adet veri ile çalışmanın yapılmış olması, başarıyı olumlu yönde etkilemiştir.

Genel olarak hem çoklu regresyonun hem de coğrafi ağırlıklı regresyonun kısıtlılıkları ve avantajlı yönleri bulunmaktadır. Değerleme uzmanları toplu değerlendirme işlerinde hangi yöntemin kendi çalışma alanlarında daha iyi sonuç verdiğini, ihtiyaçlarını karşılama konusunda daha uygun bir çözüm olduğuna odaklanmalıdırlar. Kayseri şehir merkezinde belirlenen çalışma alanı içerisinde, çoklu regresyon ve coğrafi ağırlıklı regresyon yöntemleri ile toplu değerlendirme işlemlerinin yapılabileceği anlaşılmış, veri setindeki veri sayısı ve çalışma alan sınırının optimum bir büyüklükte belirlenmesinin önemli bir gereklilik olduğu sonucuna varılmıştır.

Çok katlı binalarda yer alan konutların değerinin toplu olarak tespit edilmesinde, kentsel dönüşüm çalışmasının yapılacağı büyük alanlarda, toplu olarak yapılacak kamulaştırmalarda, konutların vergi değerlerinin belirlenmesi ve güncellenmesi gibi işlerde, çoklu regresyon ve coğrafi ağırlıklı regresyon yöntemlerinin kullanılabilir olduğu görülmüştür.

Kaynaklar

- Akış, B. (2013). *İstatistikî yöntemlerle değer belirleme ve değer haritası üretimi - Selçuklu örneği* (Yüksek Lisans Tezi). Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Alpaslan, H. İ. (2015). TMS/TFRS Kapsamında Gayrimenkul Değerleme ve Gerçeğe Uygun Değerin Tespitinde Emsal Karşılaştırma ve Gelir İndirgeme Yöntemleri Üzerine Bir Uygulama. *Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 4(2), 17-35.
- Boza, E. (2015). *Investigation of housing valuation models based on spatial and non-spatial techniques* (Doctoral dissertation). Middle East Technical University, Geodetic and Geographic Information Technologies Department, Ankara, Türkiye.
- Baran, H. (2007). *Ailelerin konut satın alma tutum ve davranışları üzerinde bir araştırma* (Yüksek Lisans Tezi). Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Chatterjee, S., Hadi, A. S., & Price, B. (2015). *Regression analysis by example*. New York, NY: John Wiley & Sons Inc.
- Demirci, N. S. (2009). *Konut sorunu bağlamında ipotekle dayalı konut finansmanı sistemi (Mortgage) ve Türkiye'de konut finansmanı* (Yüksek Lisans Tezi). Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, Kars.
- Demirel, B., Yelek, A., Alağaç, H. M., & Eren, T. (2018). Taşınmaz değerlendirme kriterlerinin belirlenmesi ve kriterlerin önem derecelerinin çok ölçütlü karar verme yöntemi ile hesaplanması. *Kırıkkale Üniversitesi Sosyal Bilimler Dergisi*, 8(2), 665-682.

- Işık, O., & Pınarcıoğlu, M. (2006). Geographies of a silent transition: A geographically weighted regression approach to regional fertility differences in Turkey. *European journal of population / Revue européenne de Démographie*, 22, 399-421.
- İlhan, A. T., & Öz, S. (2020). Yapay sinir ağlarının gayrimenkullerin toplu değerlemesinde uygulanabilirliği: Gölbaşı ilçesi örneği. *Hacettepe Üniversitesi Sosyal Bilimler Dergisi*, 2(2), 160-188.
- Khamrabaeva, L. (2020). *Gayrimenkul Değerleme Yöntemleri: Hedonik Fiyat Modeli Üzerine Bir Uygulama* (Yüksek Lisans Tezi). Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Bursa.
- Küçük Kaplan, İ., & Aldı, F. A. (2017). Denizli ilinde konut fiyatlarına etki eden faktörlerin panel verilerle analizi. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 20(37), 219-236.
- Lockwood, T., & Rossini, P. (2012, January). Efficacy of the geographically weighted model on the mass appraisal process. In *18th Annual Pacific Rim Real Estate Society Conference, 2012. Proceedings.* (pp. 1–17).
- McCord, M. J., MacIntyre, S., Bidanset, P., Lo, D., & Davis, P. (2018). Examining the spatial relationship between environmental health factors and house prices: NO₂ problem? *Journal of European Real Estate Research*, 11(3), 353-398.
- Odabaşı, G. (2020). *Türkiye’de taşınmaz değerlendirme yöntemleri ve uygulama alanlarının irdelenmesi* (Yüksek Lisans Tezi). Gebze Teknik Üniversitesi, Kocaeli.
- Osland, L. (2010). An Application of Spatial Econometrics in Relation to Hedonic House Price Modeling. *Journal of Real Estate Research*, 32(3), 289-320.
- Tabar, M. E., Başara, A. C., & Şişman Y. (2021). Çoklu regresyon ve yapay sinir ağları ile Tokat ilinde konut değerlendirme çalışması. *Türkiye Arazi Yönetimi Dergisi*, 3(1), 01-07.
- Tanrıvermiş, H. (2017). *Gayrimenkul değerlendirme esasları, SPL Sermaye Piyasası Lisanslama Sicil ve Eğitim Kuruluşu Lisanslama Sınavları Çalışma Kitapları, Ders kodu 1014*. İstanbul: Lisanslama Sınavları Çalışma Kitapları.
- TCMB. (2022, Mayıs 11). *Konut fiyat endeksi*. Türkiye Cumhuriyet Merkez Bankası. Retrieved from https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket/collapse_26/5949/DataGroup/turkish/bie_hkfe/
- Tobler, W. R. (1970). A computer movie simulating urban growth in the Detroit region. *Economic Geography*, 46(1), 234-240.
- Walacik, M. Cellmer, R., & Zrobek, S. (2013). Mass Appraisal-International Background, Polish Solution and Proposal of New Methods Application. *Geodetskii List*, 67(4), 255-269.
- Wang, D., Li, V. J., & Yu, H. (2020). Mass Appraisal Modeling of Real Estate in Urban Centers by Geographically and Temporally Weighted Regression: A Case Study of Beijing’s Core Area. *Land*, 9(5), 143. doi:10.3390/land9050143.
- Yalpır, Ş. (2007). *Bulanık mantık metodolojisi ile taşınmaz değerlendirme modelinin geliştirilmesi ve uygulaması: Konya örneği* (Doktora Tezi). Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.