



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. Mustafa ZEYBEK, Selçuk Üniversitesi, Konya, Türkiye.

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

Yabancı Dil Editörü / Language Editor

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

Sorumlu Yazı İşleri Müdürü / Managing Editor

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

Yayın Kurulu / Publishing Board

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

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

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

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

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

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

Prof. Dr. Derya ÖZTÜRK, Ondokuz Mayıs Üniversitesi, Samsun, 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 Ali YÜCEL, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, 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. Oğuz GÜNGÖR, Ankara Üniversitesi, Ankara, Türkiye.

Prof. Dr. Saygın ABDİKAN, Hacettepe Üniversitesi, Ankara, Türkiye.

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

Prof. Dr. Taşkın KAVZOĞLU, Gebze Teknik Üniversitesi, Gebze, Kocaeli, 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. Ekrem SARALIOĞLU, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

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

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

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

Doç. Dr. Özlem AKAR, Erzincan Binali Yıldırım Üniversitesi, Erzincan, Türkiye.

Doç. Dr. Uğur ALGANCI, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.



Turkish Journal of Remote Sensing and GIS
Türk Uzaktan Algılama ve CBS Dergisi

Turk J Remote Sens GIS

Journal homepage: <http://www.dergipark.gov.tr/en/pub/rsgis>

Turk J Remote Sens GIS, (2025), Cilt/Volume:6 Sayı/Issue:1 Mart/March 2025

Editör Kurulu / Editorial Board

Dr. Öğr. Üyesi Deniztan ULUTAŞ KARAKOL, Karadeniz Teknik Üniversitesi, 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, Samsun Üniversitesi, Samsun, Türkiye.

Dr. Öğr. Üyesi Resul ÇÖMERT, Eskişehir Teknik Üniversitesi, Eskişehir, Türkiye.

Dr. Öğr. Üyesi Ziya USTA, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Dr. Emre HAVAZLI, NASA JPL, Amerika Birleşik Devletleri.



İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ RESEARCH ARTICLES

- Boş Kentsel Alanların Tespiti için İHA Kullanımı: Sürdürülebilir Dolgu Gelişimi Üzerine Etkileri
Utilizing UAV for the Detection of Vacant Urban Spaces: Implications for Sustainable Infill Development
Ali Shojaeean **1 - 11**
- Açık Veri ve Türkiye'deki Durumu
Open Data and the Status in Türkiye
Muhammet Emre Yıldırım, Çetin Cömert **12 - 31**
- Copernicus Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) Verileri Kullanılarak Geçirimsizlik Derecelerinin Haritalanması ve Gelecek Tahmini: Amasya Kenti Örneği
Mapping of Imperviousness Degrees and Future Prediction Using Copernicus High Resolution Layer Imperviousness Density (HRL IMD) Data: The Case of Amasya City
Sultan Sevinç Kurt Konakoğlu, Tuğba Üstün Topal, Berkant Konakoğlu **32 - 56**
- Ayçiçeği Çiçek Tablalarının Mask R-CNN Derin Sinir Ağı ile RGB ve Multispektral İHA Ortomozaiklerinden Örnek Segmentasyonu
Instance Segmentation of Sunflower Inflorescences from RGB and Multispectral UAV Orthomosaics with Mask R-CNN Deep Neural Network
Esra Yıldırım, İsmail Çölkese, Umur Güneş Sefercik **57 - 72**
- Kentsel Alanlarda 3B Gölge Analizi: Artvin Çoruh Üniversitesi Örneği
3D Shadow Analysis in Urban Areas: Artvin Coruh University Example
Ziya Usta **73 - 81**
- Analitik Hiyerarşi Yöntemi ile En Uygun Okul Yer Seçim Analizi: Elazığ Merkez Örneği
School Site Selection Analysis Using the Analytic Hierarchy Process: The Case of Elazığ City Center
Utkan Mustafa Durdağ, Mehmet Sait Şen, Ziya Usta **82 - 95**
- Orman Yangın Alanlarında Arazi ve Toprak Örtüsündeki Değişimlerin İzlenmesi
Monitoring Changes in Land and Soil Cover in Forest Fire Areas
Betül Kırmıoğlu, Esra Tunç Görmüş **96 - 118**
- Kentsel Alanlarda Çatı Yüzey Segmentasyonu ve Fotovoltaik Potansiyel Analizinde Görsel Temel Model ve Kural Tabanlı Yaklaşımlar
Vision Foundation Models and Rule-Based Approaches for Roof Surface Segmentation and Photovoltaic Potential Analysis in Urban Areas
Samed Özdemir, Ahmet Yavuzdoğan **119 - 130**

Utilizing UAV for the Detection of Vacant Urban Spaces: Implications for Sustainable Infill Development

Boş Kentsel Alanların Tespiti için İHA Kullanımı: Sürdürülebilir Dolgu Gelişimi Üzerine Etkileri

Ali Shojaeean^{1*} 

¹Geography and Urban Planning Department, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

ORIGINAL PAPER

*Corresponding author:

Ali Shojaeean
shojaian@scu.ac.ir

doi: 10.48123/rsgis.1592089

Article history

Received: 27.11.2024
Accepted: 28.01.2025
Published: 26.03.2025

Abstract

Vacant and abandoned land are important sources of endogenous urban development. Ahvaz, one of the largest cities in southern Iran, has undergone significant physical expansion. Consequently, identifying suitable land for new development is essential for urban authorities. This research aimed to identify vacant urban land in Ahvaz using UAV images. The identification process was based on two criteria: "Urban Morphology" and "Distribution Pattern," which guided the extraction of urban vacant lands. The methodology included standardized image processing, categorization of vacant spaces, and statistical analysis to ensure accuracy and reliability. The first step was to identify the location of vacant lands in Ahvaz using images. Next, suitable locations for infill development were categorized into 6 groups based on their number and area. The density and distribution of these spaces were then examined using the index of the shape of the vacant plots and the Kernel function. The findings revealed that the largest area of vacant land was categorized as "barren with vegetation." In terms of distribution patterns, zones 2 and 1 of Ahvaz city exhibited the largest and smallest vacant land areas, respectively. This indicates a correlation between urban development levels and the availability of vacant spaces, suggesting that more developed areas tend to have fewer vacant lands. Moreover, zone 2 had the largest amount of vacant land in the town, followed by zones 8 and 6.

Keywords: UAV, Vacant urban land, Infill development, Ahvaz city

Özet

Boş ve terk edilmiş araziler, içsel kentsel gelişimin önemli kaynaklarıdır. Güney İran'ın en büyük şehirlerinden biri olan Ahvaz, önemli ölçüde fiziksel genişleme geçirmiştir. Sonuç olarak, yeni gelişim için uygun arazilerin belirlenmesi kent yetkilileri için çok önemlidir. Bu araştırma, İHA görüntülerini kullanarak Ahvaz'daki boş kentsel arazileri tespit etmeyi amaçlamıştır. Tanımlama süreci iki kritere dayanmaktadır: Kentsel boş arazilerin çıkarılmasına rehberlik eden "Kentsel Morfoloji" ve "Dağılım Modeli". Metodoloji, doğruluk ve güvenilirliği sağlamak için standartlaştırılmış görüntü işleme, boş alanların kategorizasyonu ve istatistiksel analizi içermektedir. Çalışmanın ilk adımında, İHA görüntüleri kullanılarak Ahvaz'daki boş arazilerin yerleri belirlenmiştir. Daha sonra, dolgu geliştirme için uygun yerler, sayılarına ve alanlarına göre 6 gruba ayrılmıştır. Bu alanların yoğunluğu ve dağılımı, daha sonra boş arazilerin şekil indeksi ve Kernel fonksiyonu kullanılarak incelenmiştir. Bulgular, en büyük boş arazinin "bitki örtüsüyle çorak" olarak kategorize edildiğini ortaya koymuştur. Dağılım açısından, en büyük ve en küçük boş arazi alanlarını Ahvaz şehrinin 2. ve 1. bölgeleri içermektedir. Bu durum, kentsel gelişim seviyeleri ile boş alanların mevcudiyeti arasında bir korelasyon olduğunu göstermekte ve daha gelişmiş bölgelerin daha az boş araziye sahip olma eğiliminde olduğunu düşündürmektedir. Ayrıca, 2. bölge şehirdeki en büyük boş arazi miktarına sahipken, onu 8. ve 6. bölgeler takip etmektedir.

Anahtar kelimeler: İHA, Boş kentsel arazi, Dolgu geliştirme, Ahvaz şehri

1. Introduction

The intense concentration of the population in cities of metropolises of developing countries has caused horizontal growth of cities. According to the statistical data of the World Bank, between 1960 and 2018, the number of cities with more than one million people increased from 14.14% to 24.01% (The World Bank, 2021); While at the same time, the global increase in urbanization was equal to 21.66 percent. The share of the population in the largest cities has decreased from 17.58% to 16.11% (World Bank Group, 2019). This divergence is particularly prominent in developed countries in Europe and the United States. These show the sprawl development in almost 60 years; consequently, this global problem has caused the destruction of the environment and pressure on the natural ecosystem of the earth in the outskirts of the cities and made the provision of services to city dwellers difficult (Hamidi et al., 2022). So, one of the approaches related to the balanced and logical development of the city is infill development (Arvin & Pourahmad, 2022). In this approach, instead of outward growth, vacant lands within cities are used such as barren, wasteland, brownfields, etc. (Khazaie, 2021).

The city, with all its complexity and interwoven components, in its totality, includes two main components "mass" and "space" and endogenous development can happen in masses or urban spaces. Apart from the things that can be suggested for this model of urban development, the important point is to identify and recognize these areas in different parts of the city. Conventional identification methods are often time-consuming and costly. Therefore, it is essential to use a technique that can identify areas with high accuracy and speed, as well as at a lower cost, that can be used for infill development (Peter et al., 2022). Unmanned aerial vehicles can play a role in supporting sustainable development, including infill development. UAVs can also be used to support infill development in several ways such as surveying and mapping, Environmental monitoring, and existing infrastructure, etc. This information guides the planning and design of new developments more efficiently and sustainably. UAVs are used to monitor and assess the environmental impacts of infill development. This information is important to identify potential areas of concern and inform the development of mitigation strategies. Overall, the use of UAVs in "infill development" and sustainable development more broadly can help address some of the challenges associated with urbanization and promote more efficient and sustainable development practices.

Vacant lots not only make the city look unpleasant but also usually become a place of accumulation of construction debris and household waste (Stewart et al., 2019). The accumulation of construction debris, which in turn leads to the waste piling up of garbage, threatens residents' health, and obnoxious urban landscape and vacant urban land is a significant barrier to sustainable neighborhood development (Chen & Conroy, 2023). Therefore, empty urban lands and brownfields are the prime options for redevelopment. It is currently essential for urban planners and decision-makers to identify and generally obtain locational information from vacant land (Song et al., 2020). However, accurate mapping of vacant lands has implications due to the morphology of urban spaces as it includes various features such as abandoned structures, bare land, vegetation, or a combination of them. Such diversity usually challenges their identification (Xu & Ehlers, 2022). Even when using high-resolution remote sensing images, this goal is difficult to achieve. In general, and from the aspect of typology, vacant urban land can be placed in four broad categories (Figure 1).

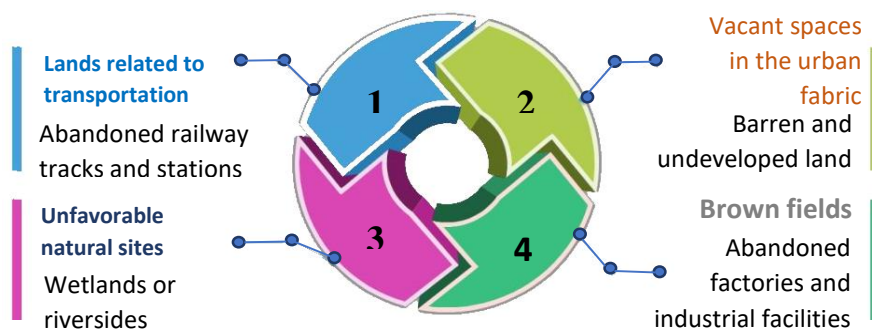


Figure 1. Typology of urban vacant land (Newman et al., 2018)

Transportation-associated land: land and spaces related to transportation systems, including railways, highways, and other roads. Natural sites: located within built-up areas, these sites have not been used due to their physical/environmental constraints. They include drainage areas, wetlands, hillsides, steep slopes, riverbanks, and rivers. Unattended areas and reserve parcels: these sites are empty and inactive and look like leftover spaces within the urban fabric. They very often feature vegetation but are not parks or gardens.

Some of these sites are already earmarked for future expansion/development. Brownfield sites: land or premises previously used and currently underused. Reusing such a site may be complicated by addressing with existing structures or contamination. Typically, there are derelict buildings or structures on site. Previous uses include industry, mining, military activities, agriculture, or commerce (Xu & Ehlers, 2022).

Examining the physical development of Ahvaz city shows that during the past decades, 58% of the physical development of the town was based on demographic changes and 42% was due to horizontal growth, also Ahvaz has greatest rates of population growth among large cities in the country. The industrial nature of the town has attracted migrants from different parts of the province and a cultural point of view, some of the citizens still have a higher birth rate than the national level, and for this reason, the population growth will continue in the medium-term future (Ahvaz, 2018). Therefore, to accommodate this population, new lands are needed for residential purposes. Vacant lands in the inner parts of the city can be one of the important opportunities to place new development. The current research aimed to develop a comprehensive method for identifying vacant urban spaces in Ahvaz using UAV photogrammetry. This approach involved a multi-step process that included image acquisition, processing, and analysis to ensure that the identified spaces were suitable for infill development.

2. Theoretical foundations

This section starts by presenting a brief overview of the different definitions of vacant land and measuring the morphology and distribution pattern of vacant urban lands.

The term vacant land is broad and diverse, but it is usually defined as under-utilized lands including bare soil, derelict land, abandoned buildings and structures, brownfields, green fields, uncultivated land, or marginal agricultural land, and recently razed land. In general, there are two representative views on the meaning of urban vacant land (UVL) to date. The first, presented by the American Planning Association, is that UVL refers to land not used for any purpose or without any buildings or other physical structures (Davidson & Dolnick, 2004). According to the second view, UVL refers to unused or abandoned land, including land that is currently unused and without any buildings, and land with buildings that have been abandoned or deserted (Nemeth & Langhorst, 2014; Kim et al., 2015). Moreover, the Chinese government established the concepts of "vacant land" and "idle land" in land management practice. The National Standard of Current Land Use Classification in China defines vacant land as a land use type referring to the unused land within an urban, village, or industrial and mining area. According to the Measures for the Disposal of Idle Land released in 2012, idle land is state-owned land which has been supplied for construction but has not reached the prescribed development intensity (Ministry of Land and Resources of the People's Republic of China, 2012). In the concepts compared above, vacant land is a positive term with no uniform definition, while idle land is a normative one that reveals policy intervention in land use. Here, a definition of UVL is presented from a positivist perspective.

From a positivist point of view, urban vacant land is unused urban land within a developed urban area, urban planning area, or urban administrative district (Song et al., 2020). From this perspective, note that an unused status with no current human activity is the key criterion for designating land as vacant land. The vacant land is not limited to land that has not been developed and constructed upon, but also includes abandoned or deserted land which has been developed with buildings, structures, and ancillary facilities (Tu et al., 2024). However, protective land and green infrastructure, such as parks and green spaces which are developed for recreation or landscape are excluded from vacant land (Anderson & Minor, 2018). Wild green spaces with no artificial management, such as wild grassland along roads or rivers within urban areas, fall within the definition of urban vacant land.

To identify the vacant lands of the study area in different evaluated classes, two macro indicators "morphology" and "distribution pattern" of vacant lands have been used.

3. Data and research method

The data obtained from aerial photography of May 2019, Unmanned Aerial Vehicle (UAV) by Shahid Chamran University, along with secondary documents. To produce a detailed map of vacant spaces suitable for infill development, the UAV images were first standardized using Agisoft PhotoScan. This process involved creating a point cloud and generating an ortho-photomap, which was then imported into ArcGIS for further analysis. The subsequent steps included identifying target areas, designing flight paths, and establishing ground control points to ensure the accuracy of the data collected. The following steps were taken to prepare the aerial images from the drone:

First identification, flight design, ground control points, and marking were designed. In the second step Ground mapping operations included creating a ground navigation station, and determine the location of the main stations and control points. In the third stage, flight operations were carried out pre- and post-flight controls, unmanned bird navigation, and receiving collected data.

Finally, data is processed through aerial triangulation, point cloud filtering, ortho-photomosaic production, control geometric correctness and output conversion comprising drawing and cartography and creating a spatial database (Majidizadeh et al., 2023). To achieve the research goals, it was realized by extracting the indicators of urban vacant spaces such as the morphology and distribution pattern of these spaces. To perform the required analysis, first the location of vacant lands of Ahvaz were identified using images and then the suitable locations for infill development were classified into 6 groups, their number and area assigned. In the following, by using the index of the shape of the vacant plots and the Kernel function, the density and distribution of the mentioned spaces were examined, and their map was produced.

3.1 Measuring the morphology of vacant urban land

As the typology indicates, the morphology of vacant land on images varies between man-made structures, bare soil, vegetation, or a mix (Xu & Ehlers, 2022). The morphology of the mentioned sections is a function of criteria such as the area of vacant plots, their average area, the number of empty blocks, and finally the shape index of empty blocks in the city, which is obtained from Equation 1 and Equation 2:

$$A_{uvl} = s / n \quad (1)$$

$$S_{iuvl} = (0.25 \times p) / \sqrt{s} \quad (2)$$

Where A is the average area of empty blocks; s is the area of an empty block; n is the number of empty blocks; Si is the shape index of empty blocks and p is the diameter of empty blocks.

3.2 Assessment of the distribution pattern of vacant urban land

The second indicator for identifying vacant urban lots is the distribution pattern of these lots. For the purpose of determine the pattern of distribution of land and vacant plots, initially, shares of parcel and area of UVL were used to measure the UVL occurrence probability: Equation 3 and Equation 4.

$$R_p = n_{uvl} / n_{lu} \quad (3)$$

$$R_a = s_{uvl} / s_{lu} \quad (4)$$

Where R_p is the proportion of UVL parcel number to total land parcel number; n_{uvl} is the number of UVL parcels; n_{lu} is the total number of whole land parcels; R_a is the proportion of UVL area to total land area; s_{uvl} is the area of UVL; and s_{lu} is the total land area. Kernel density estimation, a nonparametric method that reflects the degree of spatial aggregation of observed variables by using two-dimensional smooth estimation surfaces (Xu & Gao, 2016), was then used to estimate UVL density

3.3 The study area

Ahvaz City the center of Khuzestan province with a population of 1,262,581 people (Hosseini et al., 2024), is the seventh most populous city of Iran (Sajjadian & Daman, 2018), which is located in the southern part of the country, as seen in Figure 2.

Ahvaz is considered one of the most extensive cities in Iran. In recent decades, this city has experienced significant growth in terms of population and the size of the city due to socio-economic developments. Ahvaz metropolis includes eight urban zones that are administered by 8 municipalities (Table 1). In 1976, the area of Ahvaz was nearly 3,700 hectares. After a decade, in 1986, the size of the city reached 6900 hectares (Bahadori, 2020). With the change in the scope of the master plan, the size of the urban area changed to 8,615 hectares, In 1991. and the size of the town between 1996 and 2011 was 10,257 and 12,266 hectares, respectively. In 2012, due to the separation of Zone 5 from Ahvaz and its joining to the new city of "Kut Abdollah", the size of the city decreased to 10,709 hectares (Arvin & Zanganeh, 2020). Finally, according to the assessments from the Ahvaz Municipality Planning Department, the area of the city is estimated to be more than 18,800 hectares (Ahvaz, 2023).

According to the comparison of the number of plots and the area of empty blocks in Ahvaz and the ratio between the two, listed in Table 2, it can be seen that barren lands with vegetation and barren lands without vegetation are the most with 2.95 and 1.23, respectively. These lands have the lowest ratio between the area and the number of investigated lands. Therefore, in barren lands with vegetation, we see the most and in barren plots without vegetation,

we see the smallest dimensions and area. One of the reasons for this may be the reason that barren lands without vegetation are usually between built blocks and are ready for development. Since the ratio of the area to the number of empty plots of the city (average area) is greater than unity and equal to 1.89, it can be concluded that the area is a more important indicator of the number in any category of evaluation of the empty plots of Ahvaz city.

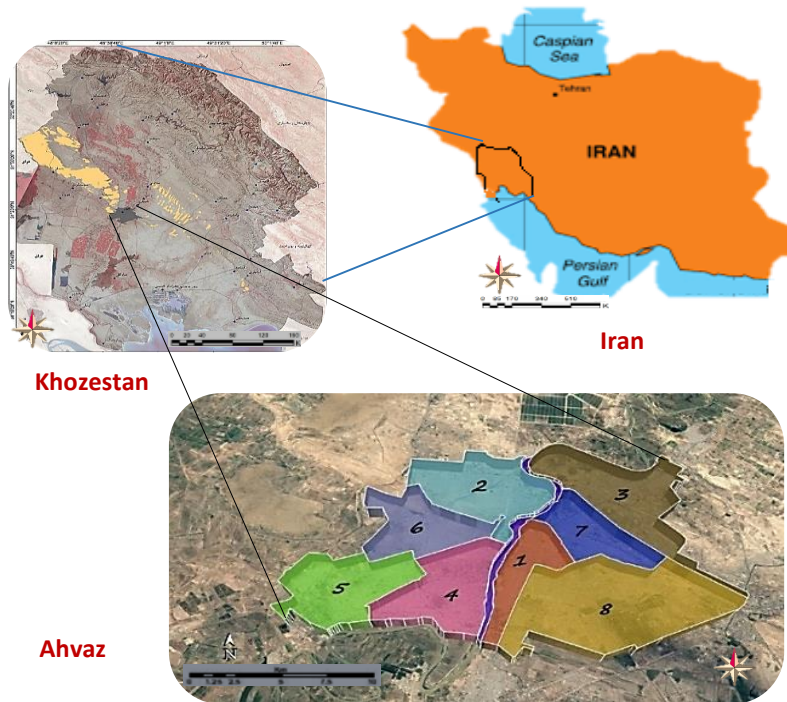


Figure 2. Location of Ahvaz city and its eight zones

Table 1. General characteristics of the eight zones of Ahvaz City (Ahvaz, 2023)

Regions	Area (ha)	Percentage of Total Area	Population of 2018	Estimated population in 2023	Percentage of the total population in 2023	Population density in 2023 (people per ha)
1	1106.6	6	13942	148583	12	135
2	2113.08	16	197274	114317	9	39
3	1318.36	18	176167	187735	15	59
4	2527.09	12	153313	163380	13	65
5	2154.74	10	105477	112402	9	52
6	2110.53	11	165110	175951	14	83
7	1718.71	10	146218	155819	12	91
8	3098.11	17	191802	204394	16	66
Total	18806.4	100	1184788	1262581	100	67

4. Results

4.1 Typology of vacant land in Ahvaz city

Vacant urban lands of Ahvaz can be classified into different types according to land cover, land use, and land ownership. Based on land cover, the vacant land of Ahvaz is divided into 6 categories such as barren with vegetation, wetland around Karun, barren without cover, barren with shrubs, and vegetation in combination with buildings and vegetation (Figure 3).

Based on land use, urban non-passage spaces can be classified into two categories 1) empty residential land and 2) empty industrial land. According to the type of ownership, lands include Private, Public, endowment, Cooperative, and Mixed ownership.

4.2 Morphology of vacant land of Ahvaz

After preparing the images and applying Equations (1) and (2), it was found that the amount of vacant land in Ahvaz city based on land cover is equal to 372 plots with an area of 701.7 hectares as seen in Figure 4. As shown in Table 2, the largest number of vacant lands was obtained from the category "barren without cover" with 106 plots, while the largest size of vacant land with 256.9 hectares belonged to "barren with vegetation". Also, the lowest amount with 28 empty plots and 65.2 hectares belongs to the class "barren with shrubs". In general, barren lands (including: barren with vegetation, barren with shrubs, and barren without cover) with a total of 446.2 hectares, occupy the majority of Ahvaz's vacant land in terms of coverage. The ratio of the number of empty plots of land to the total city plots (urban mass) is only less than 3%, while the ratio of the area of empty plots to the total area of the city is more than twice the ratio of the number and about 7.5 percentage.




Figure 3. Vacant lands of Ahvaz city based on coverage: 1) barren with vegetation, 2) wetlands around Karun river, 3) barren, 4) barren with shrubs, 5) vegetation in combination with buildings, 6) vegetation

4.3 Distribution pattern of vacant land in Ahvaz city

The distribution of the classified lands and the area of its eight zones were analyzed to evaluate more closely and examine the distribution pattern of vacant urban land in Ahvaz (Table 3). As shown in Table 3, the most and the least empty plots of land in Ahvaz with 123 and 12 belonged to zones 2 and 1 respectively. Because Zone 1 is located in the central area of the city, the small number of vacant plots seems reasonable.

The least quantity of vacant land seems to be found in more developed areas. In other words, the relationship between the development of different parts of the city and the amount of vacant land is an inverse relationship. However, even though Zone 2 is the most developed part of Ahvaz City, the presence of a high number of vacant lands is the result of annexation of the new and undeveloped neighborhood "Kian Shahr" in recent years. The ratio of the area of vacant plots to the total urban area of zones 2 and 1 is 11.97 and 2.62 hectares, respectively.

As seen in Figure 5, The highest and least average area of empty plots with 2 and 0.67 hectares are located in zones 6 and 5, respectively. The total average area of the city is equal to 1.88 hectares, which indicates that the empty lands are mostly outside the current built area. In terms of the average values of the shape index, zone 2 is still the leader with 1.95, while in terms of this index, zone 3 has the least number with values of 1.28.

The largest number of vacant lands in Ahvaz were identified in zones 2, 8, and 4, respectively, while the least are found in zones 1, 7, and 5. Regarding area, zone 2 is still the first rank of vacant land in the city, and zones 8 and 6 in the next. By examining other data in (Table 3), it is clear that Zone 2 of Ahvaz Municipality is not ranked first only in the index of the average area of vacant blocks. Also, this zone ranks fourth and second in terms of the number and total area of city blocks.

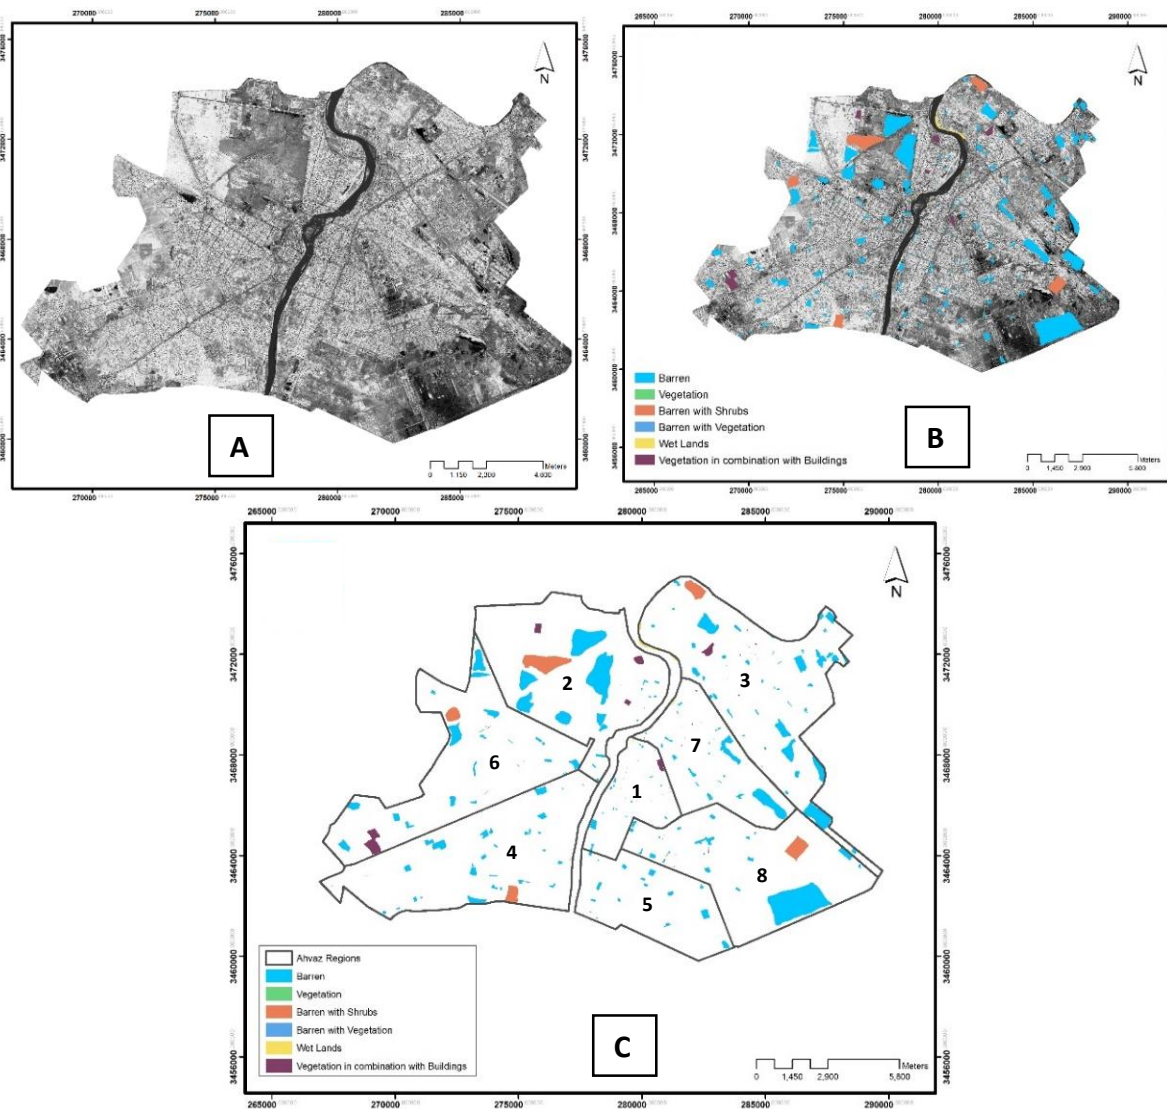


Figure 4. Vacant land in Ahvaz based on land cover: A) mosaic images, B) vector and raster image, C) vacant land map of Ahvaz

Table 2. Types of empty land in Ahvaz city based on land cover

	Number of parts	Area of parts (ha)	Average area of vacant block (ha)	Probability of Occurrence(%)	
				Ratio number of empty plots to total number of plots	Ratio area of empty plots to the total area
Barren with vegetation	88	259.6	2.95	0.76	2.76
Wet lands around Karun	48	79.3	1.65	0.36	0.84
Barren without vegetation	106	131.4	1.23	0.79	1.39
Barren with shrubs	28	65.2	2.32	0.21	0.69
Vegetation in combination with buildings	35	68.9	1.97	0.26	0.73
Vegetation	67	97.3	1.45	0.5	1.03
Total	372	701.7	1.89	2.79	7.45

Table 3. Morphological characteristics of vacant urban land plots in the 8 zones of Ahvaz

Zone	Total number of blocks	The total area of blocks (ha)	Number of blocks	Area of empty blocks (ha)	The average area of vacant block (ha)	Probability of Occurrence(%)		Average of Shape Index
						The average area of vacant block (ha)	The ratio of the area of empty blokes to the total area of the city	
1	1378	726.34	12	19.6	1.63	0.87	2.69	1.32
2	1471	1549.56	123	185.5	1.50	8.36	11.97	1.95
3	1839	1343.61	34	39.4	1.15	1.84	2.93	1.28
4	1601	1090.18	49	55.3	1.12	3.06	5.07	1.35
5	1592	913.66	32	21.5	0.67	2.01	2.35	1.48
6	1072	1000.91	34	68.2	2	3.16	6.81	1.65
7	1414	1157.21	19	31.7	1.66	1.34	2.73	1.39
8	2941	1631.06	69	69.5	1	2.34	4.26	1.31
Total	13308	9412.53	372	701.7	1.88	2.79	7.45	1.35

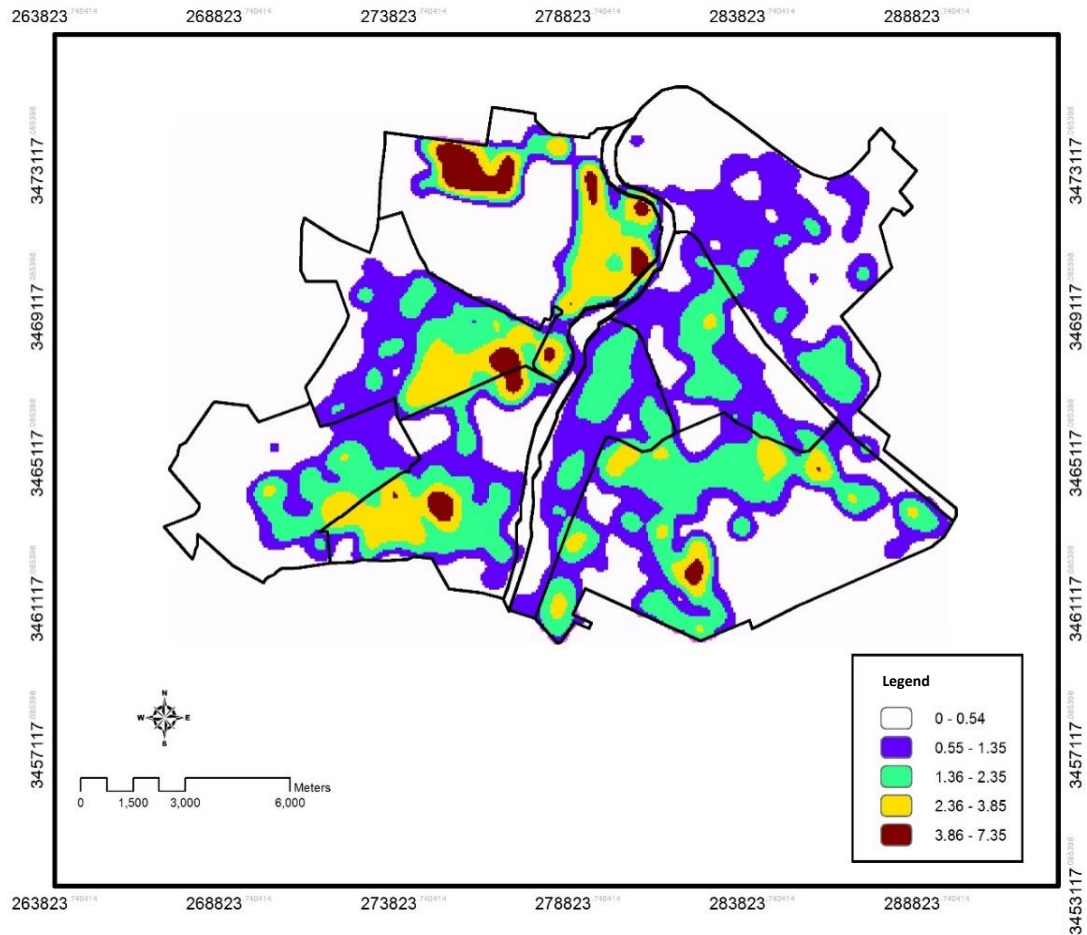


Figure 5. Distribution pattern of vacant lands in Ahvaz based on the average shape index and using Kernel

By comparing the three key indicators of the research (the ratio of vacant plots to the total city plots, the ratio of empty area to the total area of the city, and the average values of the shape index) and by examining the eight zones of the city, it was found that the 5th zone of Ahvaz municipality has the most harmony and homogeneity in terms of the indicators. In this context, zones 3, 7, and 1 are in the next places. From this point of view, zones 2, 6, and 4 have the least homogeneity, as seen in Figure 6.

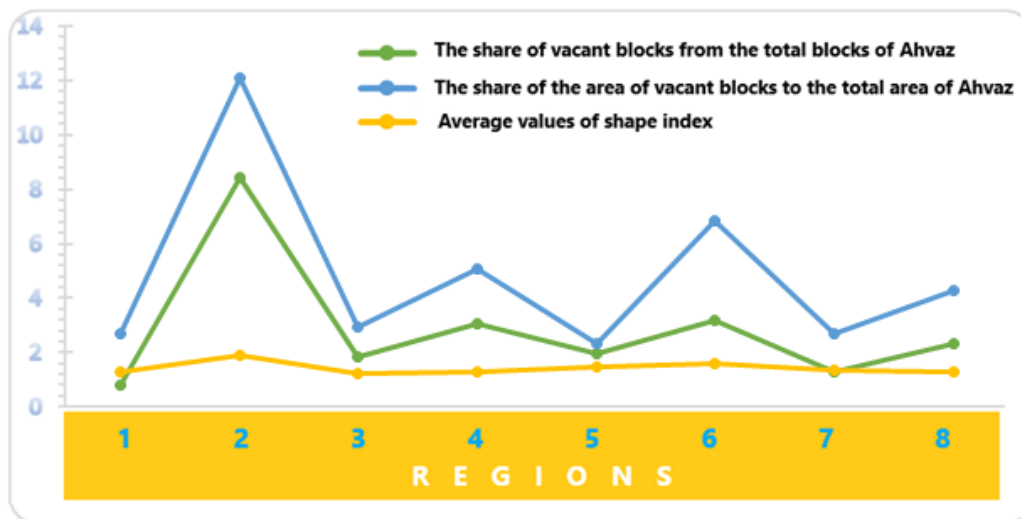


Figure 6. Comparison chart of three key research indicators

4.4 Verification of Results

To establish the reliability of the identified vacant lands, a comprehensive verification process was undertaken. This included systematic ground truthing through field visits, wherein researchers meticulously compared the mapped data with actual conditions observed on-site. This assessment involved evaluating the accuracy of the identified vacant spaces against empirical observations, thereby ensuring the integrity of the data.

Furthermore, advanced statistical analyses were conducted utilizing shape indices and Kernel functions to rigorously evaluate the density and spatial distribution of the vacant lands. These analyses provided quantitative metrics to confirm that the observed patterns were statistically significant, thereby reinforcing the validity of the findings and their implications for urban planning and development.

5. Conclusion

The lack of land for housing construction in developing countries is a prevalent issue exacerbated by rapid urbanization. This study highlights the potential of infill development in utilizing vacant urban spaces, particularly in Ahvaz, where over 372 vacant plots covering more than 700 hectares were identified. By employing UAV technology for accurate mapping, the research not only provides a framework for identifying underutilized lands but also emphasizes the importance of sustainable urban development practices. The findings advocate for the strategic use of these vacant lands to accommodate population growth while minimizing environmental impacts, thus contributing to more efficient urban planning. With more and more people living in urban areas, agricultural and natural areas are being increasingly built over, causing land needed for natural habitats and food production to be lost. At the same time, rapid urbanization has resulted in fragmented urban development and the abandonment of infrastructures, meaning that many metropolitan areas have become vacant land indicated by their unused, underused, derelict, or abandoned situation. Sustainable urban development makes the reuse, redevelopment, or recycling of such areas a key strategy for reducing land consumption and combating urban sprawl.

One of the solutions to face this problem is infill development in unused vacant spaces in the urban mass. Identifying these spaces is often associated with obstacles and difficulties such as time and cost.

The use of traditional and field methods to identify vacant land in the city and also considering the area of 20 thousand hectares of Ahvaz city cannot be efficient. Moreover, the existence of unused spaces in the center and outskirts of urban masses also makes the problem more complicated. Current research on vacant land is mainly approached from an urban planning perspective the objective of identifying the vacant lands of Ahvaz with the ability to be used in the infill development using drone areal images. To achieve this goal, two major indicators of the morphology of empty urban land and the distribution pattern of empty spaces in the city of Ahvaz were used.

The results of the research showed that out of the total number of 13308 urban plots and blocks in Ahvaz, 372 are vacant spaces that can be used for infill development. This number includes an area of more than 700 hectares from the area of about 9412 hectares of Ahvaz city. In general, the number of vacant spaces is 2.79% of the total number of plots and 7.45% of the total area of Ahvaz urban mass.

Based on land cover and regarding to the six classes of research, the largest number with 88 cases and an area of 259.6 hectares, includes 2.76% of the vacant plots of the city. The vegetation layer combined with the building, with 35 cases and an area of 68.9 hectares, was the least covered case with 0.73 hectares.

Most of the plots and vacant lands are located in zone 2 in the northwestern area of Ahvaz, which has the highest development rating of the city due to the annexation of the Kianshahr area to the urban fabric and this area of the town in the recent years. Zone 1 is located in the central part and has the least number of vacant lands where there are the oldest structures of Ahvaz.

From a spatial point of view, the city of Ahvaz can be divided into two parts by the river of Karun. The western part including zones 2, 4, 6, and 5 has the highest number of vacant plots which could be used for infill development (as seen in Figure 5). While in the opposite part, which includes zones 3, 1, 7, and 8 with a total area of 4,858.22, having a larger area has a smaller number of vacant plots in the western part of the river.

By analyzing the data and the discussion, the research recommended the following proposals: 1) The vacant lands of the research area from the point of view of land use and ownership should also be calculated and compared with the findings of this study. 2) By calculating the capacity of identified vacant lands, their population potential should be calculated from different aspects. 3) Utilizing GIS and the involvement of factors such as access to the highway, identified vacant lands should be prioritized for infill development (as seen in Figure 6).

References

- Ahvaz, S. C. (2018). *Report of the second five-year plan for the development and construction of Ahvaz city during the period 2017–2018*. <https://planning.ahvaz.ir/Portals/3/FilesSubDomain/pdf/pdf-94/5sale>
- Ahvaz, S. C. (2023). *Statistical report of Ahvaz metropolis 2023*. <https://planning.ahvaz.ir/Portals/3/FilesSubDomain/pdf/amarname1402/amar-1402.pdf>
- Anderson, E. C., & Minor, E. S. (2018). Assessing social and biophysical drivers of spontaneous plant diversity. *The Science of the Total Environment*, 653, 1272–1281. <https://doi.org/10.1016/j.scitotenv.2018.10.440>
- Arvin, M., & Zanganeh, S. (2020). Investigation of barriers to infill development approach: A case study of Ahvaz City. *Journal of Sustainable City*, 3(1), 71–87.
- Arvin, M., & Pourahmad, A. (2022). Structural modeling of measuring social acceptance of compact cities. *Geographical Studies of Desert Areas*, 10(1), 189–216.
- Bahadori, B. (2020). Evaluation and analysis of the horizontal expansion of Ahvaz metropolis. *Urban Studies Quarterly*, 3(8), 4–19.
- Chen, L., & Conroy, M. M. (2023). Vacant urban land temporary use and neighborhood sustainability. *Journal of Urban Affairs*, 46(10), 2084–2108. <https://doi.org/10.1080/07352166.2023.2168551>
- Davidson, M., & Dolnick, F. (2004). *A planner's dictionary (Planning Advisory Service Report Number 521/522)*. American Planning Association. https://planning-org-uploaded-media.s3.amazonaws.com/publication/download_pdf/PAS-Report-521-522.pdf
- Hamidi, M. S., Heidarlou, H. B., Furst, C., & Nazmfar, N. (2022). Urban infill development: A strategy for saving peri-urban areas in developing countries: The case study of Ardabil, Iran. *Land*, 11(4), Article 454. <https://doi.org/10.3390/land11040454>
- Hosseini, S. M., Amanpour, S., & Maleki, S. (2024). Predicting and explaining the structural components of demographic changes in the metropolis of Ahvaz. *Geography and Urban Space Development*, 11(3), 83–106.
- Khazaie, Z. (2021). *Infill development: Urban growth strategy*. Entekhab Publications.
- Kim, G., Miller, P. A., & Nowak, D. J. (2015). Assessing urban vacant land ecosystem services: Urban vacant land as green infrastructure in the city of Roanoke, Virginia. *Urban Forestry & Urban Greening*, 14(3), 519–526.
- Majidizadeh, A., Hasani, H., & Jafari, M. (2023). Semantic segmentation of UAV images based on U-Net in urban areas. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-4/W1, 19–25.
- Ministry of Land and Resources of the People's Republic of China. (2012). *Regulation on idle land disposal (06-01)*. <https://www.mayerbrown.com/en/perspectives-events/publications/2012/06>
- Nemeth, J., & Langhorst, J. (2014). Rethinking urban transformation: Temporary uses for vacant land. *Cities*, 40, 143–150. <https://doi.org/10.1016/j.cities.2013.06.007>
- Newman, G., Park, Y., Bowman, A. O. M. & Lee, R. J. (2018). Vacant urban areas: Causes and interconnected factors. *Cities*, 72, 421–429. <https://doi.org/10.1016/j.cities.2017.10.005>
- Peter, N. J., Fateye, T. B., Okagbue, H. I., Abonta, G., & Ibisola, A. S. (2022). Infill development and its attendant consequences on property value: Evidence from Gwarinpa, Abuja, Nigeria. *International Journal of Mechanical and Production Engineering Research and Development (IJMPERD)*, 10(3), 2203–2218.
- Sajjadian, N., & Daman, B., S. (2018). Analyzing the role of the political environment and mental perception in the difference in the vitality level of Ahvaz citizens. *Zagros Landscape Geography and Urban Planning Quarterly*, 13(4), 143–166.
- Song, X., Wen, M., Shen, Y., Feng, Q., Xiang, J., Zhang, W., Zhao, G., & Wu, Z. (2020). Urban vacant land in growing urbanization: An international review. *Journal of Geographical Sciences*, 30(4), 669–687.
- Stewart, W. P., Gobster, P. H., Rigolon, A., Strauser, J., Williams, D. A., & van Riper, C. J. (2019). Resident-led beautification of vacant lots that connects place to community. *Landscape and Urban Planning*, 185, 200–209.
- The World Bank. (2021). *Urban population - European Union*. <https://data.worldbank.org/indicator/SP.URB.TOTL.IN.ZS?locations=EU>.
- Tu, T., Wang, X., & Long, Y. (2024). Spatiotemporal changes of urban vacant land and its distribution patterns in shrinking cities on the globe. *Science of the Total Environment*, 947, Article 174424. <https://doi.org/10.1016/j.scitotenv.2024.174424>
- Xu, S., & Ehlers, M. (2022). Automatic detection of urban vacant land: An open-source approach for sustainable cities. *Computers, Environment and Urban Systems*, 91, Article 101729. <https://doi.org/10.1016/j.compenvurbsys.2022.101729>
- Xu, Z. N., & Gao, X. L. (2016). A novel method for identifying the boundary of urban built-up areas with POI data. *Acta Geographica Sinica*, 71(6), 928–939. <http://www.geog.com.cn/EN/Y2016/V71/I6/928>
- World Bank Group. (2019). *World Bank data*. <http://data.worldbank.org.cn/indicator>

Açık Veri ve Türkiye'deki Durumu

Open Data and the Status in Türkiye

Muhammet Emre Yıldırım^{1*}, Çetin Cömert²

¹Mapisso Yazılım, 35580, İzmir/Türkiye.

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Muhammet Emre Yıldırım
meyildirim@mapisso.com

doi: 10.48123/rsgis.1601908

Yayın süreci

Geliş tarihi: 15.12.2024
Kabul tarihi: 19.02.2025
Basım tarihi: 26.03.2025

Özet

Açık veri nedir? sorusu, özellikle veri paylaşım ortamını henüz sağlıklı bir şekilde hayata geçirememiş Türkiye gibi ülkelerde önemini halen korumaktadır. Bu çalışmada, özellikle konumsal verilerin, açık veri olarak nasıl paylaşılması gerektiği konusuna odaklanılmıştır. Bu çalışma kapsamında bir verinin açık veri olarak kabul edilmesi için sağlaması gereken koşullar net bir şekilde ifade edilmektedir. Ülkemizde yapılan açık veri çalışmaları teknik yönden incelenmiş ve tespit edilen eksiklikler ifade edilmiştir. Açık veriye geçiş yapacak tüm kurum ve kuruluşların, açık veriye geçiş sürecini sağlıklı bir şekilde yönetebilmesi için açık veri yol haritası, bu çalışma kapsamında yayınlanmıştır. Bu yol haritası, açık veri ekosisteminin oluşturulması bakımından tüm gereksinimleri kapsayıcı bir şekilde hazırlanmıştır. Açık veri konusundaki teknik çalışmaların yanı sıra açık veri çalışmalarını bağlayacak kanuni altyapı incelenmiş ve ülkemizde açık veri yaklaşımının net bir şekilde anlaşılmadığı görülmektedir. Özellikle, konumsal verinin üretimi, paylaşılması konusunda yayınlanan kanun ve yönetmeliklerdeki engelleyici hükümlerin acil şekilde yürürlükten kaldırılması gerekmektedir. Konumsal verilerin serbest bir şekilde dağıtımını engelleyecek hükümler, ülkemizde hayata geçirilecek açık veri altyapılarının, yetersiz bir seviyede kalmasına sebep olmaktadır. Hızlı bir şekilde, açık veri yaklaşımının önünü açacak kanuni düzenlemelerin yapılması ve bunu takiben destekleyici kanun ve yönetmeliklerin oluşturulması gerekmektedir.

Anahtar kelimeler: Açık veri, Konumsal veri, Açık veri yol haritası

Abstract

The question of what is open data? is still important, especially in countries like Türkiye that have not yet implemented a healthy data sharing environment. This study focuses on how spatial data should be shared as open data. At this study, open data rules are clearly stated. Open data studies in our country have been technically examined and the identified deficiencies have been stated. An open data roadmap has been created so that all institutions and organizations that will transition to open data can manage the open data transition process in a healthy way. This roadmap has been prepared in a way that covers all the requirements for the creation of an open data ecosystem. Beyond the technical studies on open data, the legal infrastructure that will affect open data studies has been examined and it has been seen that the open data approach is not clearly understood in our country. In particular, the prohibitive provisions in the laws and regulations published on the production and sharing of spatial data must be urgently repealed. These provisions cause the open data infrastructures to be implemented in our country to remain at an inadequate level. It is necessary to quickly make legal arrangements that will pave the way for the open data and then create supporting laws and regulations.

Keywords: Open data, Spatial data, Open data roadmap

1. Giriş

Açık veriye olan ihtiyacın, ilk olarak Ulusal Bilimler Akademisi (National Academy of Sciences) tarafından 1995 yılında yayınlanan jeofiziksel ve çevresel verilerin paylaşılması hakkındaki bir raporda ifade edildiği görülmektedir (National Research Council, 1995). Açık verinin bilimsel çalışmalardaki önemi, bu rapordaki “*atmosferimiz, okyanuslarımız ve biyosferimiz, sınırları aşan entegre bir bütün oluşturur*” (National Research Council, 1995) cümlesiyle ortaya çıkmaktadır. Bu rapordaki asıl amaç, bilimsel çalışmalar ve bu çalışmalardaki verilerin tamamıyla açık bir şekilde paylaşılması gerekliliğini vurgulamaktır (Chignard, 2013). Bir verinin açık bir şekilde paylaşılmasının değeri, ilk olarak bilimsel araştırma yapan araştırmacılar tarafından fark edilmiştir.

2007 yılına gelindiğinde, Amerika’da internet konusunda çalışmalar yürütmüş 30 internet aktivisti (Open Government Working Group, 2007) tarafından San Francisco’da bir toplantı düzenlenmiştir. Bu toplantının amacı, açık kamu verisi kavramını tanımlamak ve ABD başkan adayları tarafından açık kamu verisi fikrinin benimsenmesini sağlamaktır. Bu toplantı sonucunda, 8 maddelik açık hükümet verisi prensipleri yayınlanmıştır (https://public.resource.org/8_principles.html).

2009 yılında eski ABD başkanı Barack H. Obama’nın, *Şeffaflık ve Açık Hükümet Hakkında Memorandum* yayınlanmasıyla açık veri çalışmaları hızlanmıştır (Obama, 2009). 2009 yılında, hiperlink (hyperlink) ve internetin mucidi olarak görülen Sir Tim Berners-Lee, TED konferansında, “Raw data, now!” (Ham veri, şimdi!) başlıklı sunumuyla, açık veri çalışmalarının hızlanmasına katkı sağlamıştır (Berners-Lee, 2012). Açık veri çalışmaları, hızla gelişmiş ve dünyadaki pek çok ülke açık veri çalışmalarını hızlı bir şekilde yürütmüştür. Açık verilerin bulunmasını ve görüntülenmesini sağlayan pek çok açık veri portalı yayınlanmıştır (Tablo 3). Amerika Birleşik Devletlerinden Birleşik Krallığa, Almanya’dan İspanya’ya kadar pek çok ülkenin açık veri portallarını geliştirerek yayına aldığı görülmektedir. Ülkelerin yanı sıra, yerel yönetim düzeyinde kentlerin de kendi açık veri portallarını yayına aldığı görülmektedir (Tablo 4).

Ülkemizde son yıllarda kamu kurumlarının açık veri çalışmalarına başladığı görülmektedir. Ülkemizdeki açık veri çalışmalarına yönelik yapılan incelemeler sonucunda, açık veri yaklaşımının net bir şekilde anlaşılmadığı görülmektedir. Bu çalışma kapsamında, açık veri çalışmalarında yaşanan olumsuzlukların çözülebilmesi ve bir verinin açık veri olarak kabul edilebilmesi için sağlanması gereken koşullar net bir şekilde ifade edilmektedir. Ülkemizde açık veri çalışmalarının henüz başlangıç noktasında olduğu ve bu çalışmaların nasıl daha ileriye götürüleceğine dair öneriler bu çalışma kapsamında ifade edilmiştir. Katma değeri yüksek verilerin, açık veri olarak yayınlanmasının çok kısıtlı düzeyde kaldığı görülmektedir. Açık veri ekosisteminin sürdürülebilirliği için katma değeri yüksek verilerin açık veri olarak yayınlanması, açık veri kültürünün ülkemizde hızla genişlemesine yardımcı olacaktır. Bu doğrultuda, bir kamu kurum veya kuruluşunun açık veri yaklaşımını hayata geçirmeyi istemesi durumunda izlenecek yol haritası, bu çalışma kapsamında ortaya konulmuştur. Bu yol haritası, açık veriye geçiş yapacak kurum ve kuruluşlar tarafından kullanılmasıyla, açık veri ekosisteminin daha sağlıklı bir şekilde hayata geçirilmesini sağlayacaktır.

Ülkemizdeki hukuksal altyapı göz önüne alındığında, bir açık veri ekosisteminin hayata geçmesi ve sürdürülebilir bir şekilde yaşamına devam etmesine zarar verecek kanun ve yönetmelikler olduğu görülmektedir. Kamu kurum ve kuruluşlarının açık veriye geçişte isteksiz olması, mevcut kanun ve yönetmeliklerde açık veri ekosistemine geçişte çeşitli engelleyici hükümlerin olması açık veri çalışmalarının ülkemizde yavaş bir şekilde ilerlemesine veya hiç başlayamamasına neden olmaktadır. Konumsal verilerin serbest bir şekilde dağıtımını engelleyecek hükümler, ülkemizde hayata geçirilecek açık veri altyapılarının, yetersiz bir seviyede kalmasına sebep olmaktadır. Bu çalışmada, açık veri bağlamında, ülkemizdeki hukuksal altyapı incelenmiş ve açık veri yaklaşımına zarar verecek hükümler irdelenmiştir.

2. Açık veri nedir?

Açık veri, herkes tarafından herhangi bir amaç için kullanılabilen, düzenlenebilen ve paylaşılabilen veridir (Open Knowledge Foundation, 2012). Veri sağlayıcılarının yayımladıkları verinin, açık veri olarak tanımlanabilmesi için aşağıdaki koşulların sağlanması gerekmektedir (Open Knowledge Foundation, 2012). Açık veri;

1. *Kullanılabilirlik ve erişilebilirlik*; verinin internet üzerinden ücretsiz bir şekilde erişilebilir olması koşuldur. Verinin bir kısmının değil tamamının indirilebilir olması gerekmektedir.
2. *Açık ve makine tarafından okunabilir* veri formatında olmalıdır.
3. *Yeniden kullanım ve yeniden dağıtım*; veri yeniden kullanıma ve üretime açık olmalı, farklı veri setleri ile birleştirilebilir ve yayınlanabilir olmalıdır.
4. *Evrensel erişim*; herkes kullanabilmelidir. Belirli bir grubun veya özel sektörün kullanımının engellenmesini veya belirli bir grubun erişimine açılmasını sağlayacak kısıtlamaların bulunmaması gerekmektedir.
5. *Açık veri lisansına* tabi olmalıdır.

2.1. Kullanılabilirlik ve Erişebilirlik

Bir verinin internet ortamında web sayfasında görüntülenebilir olması, tek başına o verinin açık veri olarak kabul edilmesi için yeterli değildir. İlgili verinin internet üzerinden *ücretsiz bir şekilde* indirilebilir olması gerekmektedir. Verinin bir kısmının değil tamamının indirilebilir olması gerekmektedir (Open Knowledge Foundation, 2012).

2.2. Açık ve Makine Tarafından Okunabilir Format

Yayınlanan verinin açık veri olarak kabul edilebilmesi için, *ticari bir yazılım formatının kullanılmaması* gerekmektedir. Kullanılan veri formatının makine tarafından okunabilir formatta olması gerekmektedir. Örneğin; bir tablo verisinin tarayıcı kullanılarak taranıp bir resim formatında yayınlanması o verinin açık veri olarak nitelenmesini engellemektedir. Bunun yerine ilgili tablo verisinin CSV (Comma Separated Values, Virgülle Ayrılmış Değerler) veri formatında yayınlanması, ilgili verinin açık veri olarak yayınlanabilir hale gelmesini sağlamaktadır (Open Knowledge Foundation, 2012).

2.3. Yeniden Kullanım ve Yeniden Dağıtım

Yayınlanan verinin, başka veri setleri ile karıştırılması da dahil olmak üzere, herhangi bir kullanıcının kendi ortamında veriyi *tekrar tekrar kullanabilmesi ve dağıtabilmesine izin veren koşullar* altında yayınlanması gerekmektedir (Open Knowledge Foundation, 2012). Açık veri kullanıcısının, veriyi indirdikten sonra hiç değişiklik yapmadan ya da başka bir veriyle birleştirerek yayınlamasının önünde herhangi bir engel olmamalıdır.

2.4. Evrensel Erişim

Yayınlanan veri, herkes tarafından erişilebilir ve kullanılabilir olmalıdır. *Herhangi bir grup ya da kurumun kullanımına özel sınırlamaların olmaması* gerekmektedir (Open Knowledge Foundation, 2012). Örneğin; bir belediye sahip olduğu veriyi sadece belediye çalışanlarının kullanımına açmış ise bu veriler açık veri olarak nitelendirilemez. Ayrıca belli gruplara kısıtlamaların olması da evrensel erişimi ortadan kaldıran bir durumdur. Örneğin; bir verinin ticari amaçlar için kullanılmasını engelleyen bir koşul var ise bu durumda ilgili verinin açık veri olarak tanımlanması mümkün olmamaktadır.

2.5. Açık Veri Lisansı

Verinin açık veri olarak kabul edilebilmesi için en önemli koşul, ilgili verinin bir açık veri lisans koşulları altında kullanıma sunulmuş olmasıdır (Open Knowledge Foundation, 2012). Lisans koşulları belirsiz olan bir veri, herhangi bir şekilde açık veri olarak kabul edilemez. *Creative Commons CCZero* (Creative Commons, 2013a), *Open Data Commons Public Domain Dedication and Licence* (Open Data Commons, 2008) ve *Creative Commons Attribution 4.0* (Creative Commons, 2013b) gibi açık veri lisansları, açık veri lisanslamalarında kullanılacak bazı açık veri lisanslarıdır. Veri için tanımlanmış lisans koşullarının, temel açık veri koşullarını sağlıyor olması gerekmektedir.

Tablo 1. Lisans listesi ve koşulların karşılaştırması

Lisans Adı	Atif Gerekiyor mu?	Aynı Koşullarda Paylaşmalı mı?
Creative Commons CCZero (Creative Commons, 2013a)	Hayır	Hayır
Open Data Commons Public Domain Dedication and Licence (Open Data Commons, 2008)	Hayır	Hayır
Creative Commons Attribution 4.0 (Creative Commons, 2013b)	Evet	Hayır
Open Data Commons Attribution License (Open Knowledge Foundation, 2009a)	Evet	Hayır
Creative Commons Attribution Share-Alike 4.0 (Creative Commons, 2013c)	Evet	Evet
Open Data Commons Open Database Licence (Open Knowledge Foundation, 2009)	Evet	Evet

Açık veri lisansları Tablo 1’de, atıf gerektirme durumu ve aynı koşullarda paylaşma başlıklarıyla irdelenmiştir. Atıf gerektirme durumu; bu koşula sahip bir açık veri lisansı ile yayınlanan verinin kaynağı hakkında atıf yapma zorunluluğu getirmektedir. Aynı koşullarda paylaşılma durumu; bu koşula sahip bir açık veri lisansı ile yayınlanan verinin üzerinde işlem yapılması ya da yeniden yayınlanması durumunda, orijinal veri kaynağındaki lisans koşulu ile yayınlanması zorunluluğu getirmektedir. Bu açık veri lisansları dışında ülkelerin, kent yönetimlerinin oluşturduğu açık veri çalışmaları için oluşturmuş olduğu açık veri lisanslarının da yayınlandığı görülmektedir (Tablo 2).

Tablo 2. Ülkelerin ve şehir belediyelerinin açık veri lisans örnekleri

Lisans Adı	Atıf Gerekliyor Mu?	Aynı Koşullarda Paylaşmalı Mı?
U.S. Government Works-Public Domain (https://www.usa.gov/government-works)	Hayır	Hayır
Open Government Licence v3 (The National Archives, 2023)	Evet	Hayır
Data Licence Germany-Attribution-Version 2.0 (https://www.govdata.de/dl-de/by-2-0)	Evet	Hayır
İstanbul Büyükşehir Belediyesi Açık Veri Lisansı v1.0 (https://data.ibb.gov.tr/license)	Evet	Hayır
İzmir Büyükşehir Belediyesi Açık Veri Lisansı (https://acikveri.bizizmir.com/tr/license)	Evet	Hayır

Tablo 2’ de bazı ülkelerin ve şehir belediyelerine ait açık veri lisanslarına ilişkin örnekler bulunmaktadır. *U.S. Government Works* lisansı (<https://www.usa.gov/government-works>), A.B.D.’de gerçekleştirilen açık veri çalışmalarında kullanılan açık veri lisansıdır. *Open Government Licence v3* lisansı (The National Archives, 2023), Birleşik Krallık’ta gerçekleştirilen açık veri çalışmalarında kullanılan açık veri lisansıdır. *Data Licence Germany-Attribution-Version 2.0* lisansı (<https://www.govdata.de/dl-de/by-2-0>), Almanya’da gerçekleştirilen açık veri çalışmalarında kullanılan açık veri lisansıdır. İstanbul Büyükşehir Belediyesi Açık Veri Lisansı v1.0 lisansı (<https://data.ibb.gov.tr/license>), İstanbul Büyükşehir Belediyesi tarafından gerçekleştirilen açık veri çalışmalarında kullanılan açık veri lisansıdır. İzmir Büyükşehir Belediyesi Açık Veri Lisansı v1.0 lisansı (<https://acikveri.bizizmir.com/tr/license>), İzmir Büyükşehir Belediyesi tarafından gerçekleştirilen açık veri çalışmalarında kullanılan açık veri lisansıdır. Tablo 2’de gösterilen İstanbul ve İzmir Büyükşehir Belediyeleri tarafından tanımlanan lisanslar, CC BY 4.0 lisansı (Creative Commons, 2013c) baz alınarak hazırlanmıştır. Kent seviyesinde farklı açık veri lisansı oluşturulmasının getireceği sorunlar ilerleyen başlıklar altında değerlendirilmektedir.

3. Neden Açık Veri?

Verinin geçmişten günümüze gelen üretimi ve kullanımına bakıldığında, bilgisayar ve internet teknolojilerinin gelişmesinden önceki dönemde, basılı kağıtlar yoluyla arşivlerde depolanmakta olduğu, bilgisayar teknolojilerinin gelişmesiyle, ilk etapta yerel ağ yoluyla birbirine bağlı kısıtlı sayıdaki bilgisayarların disklerinde depolandığı, internet teknolojilerinin gelişmesiyle birlikte kurumlar ve şirketlerin, ilk etapta kendi içerisinde bilgi paylaşımını sağlayacak çeşitli web uygulamaları geliştirmeye başladığı görülmektedir (Yıldırım, 2023).

Son zamanlara gelindiğinde, çeşitli kamu kurum ve kuruluşları çeşitli veri ve hizmetlerini güncel teknolojiler kullanarak web uygulamaları vasıtasıyla sunmakta, verinin web sunucusu disklerinde ve veri tabanı gibi ortamlarda depolandığı görülmektedir. Geçmişten günümüze, tüm bu veri depolama ve sunma hizmetleri değerlendirildiğinde, verinin saklanma ve sunulma araçlarının değişmesinin yanı sıra veriye erişim şekli konusunda çok da büyük değişimlerinin yaşanmadığı görülmektedir. Verinin, bilgisayar ve internet teknolojilerinin gelişmesinden önce, kâğıt arşivlerde erişimden uzakta, daha sonraları bilgisayarda kısıtlı sayıdaki kişilerin erişebileceği şekilde, son günlerde internet ortamında kısıtlı yetenek seti olan web uygulamalarının arkasında saklandığı görülmektedir (Yıldırım, 2023).

Özellikle kamu kaynaklarının etkin yönetiminde, çok sayıda kamu kurumunun farklı alanlarda ürettikleri verilere anlık erişimin sağlanması oldukça önem arz etmektedir. Kâğıt arşiv, kısıtlı yetenek setine sahip web uygulamalarından sonra, günümüzde bu verilerden katma değer üretebilmek için veri ne şekilde paylaşılmalıdır? Günümüzde dünya genelinde bu sorunun kabul görmüş cevabı; açık veri yaklaşımıdır.

Açık veri yaklaşımı ile verinin sahip olduğu potansiyelin serbest bırakılması sağlanmaktadır. Verinin gerçek potansiyelini ortaya çıkarmak için bu verinin herhangi bir kullanıcıya herhangi bir ücret ve kısıtlama olmaksızın paylaşılması gerekmektedir (Yıldırım, 2023).

Ülke ve kent yönetimlerinin açık veri yaklaşımını benimsemesi oldukça önem arz etmektedir (Yıldırım, 2023). Dünyada ve ülkemizde en büyük veri üreticilerinin kamu kurumları olduğu göz önüne alındığında, yaratacağı etki bakımından kamu kurum ve kuruluşlarının sahip oldukları verileri, açık veri lisans koşulları altında paylaşması oldukça önemlidir. Açık veri yaklaşımının; ülke ve kent yönetiminde, demokrasiyi güçlendirmesi, halka verimli ve etkili hizmet sunulması, ekonomik büyümeye katkıda bulunması bakımından son yıllarda oldukça popüler hale geldiği görülmektedir (The White House, 2013). Demokratik ülke yönetimlerinde en önemli bileşenlerden birisi şeffaflıktır (Hollyer vd., 2011). Günümüzde, yönetimde şeffaflığın sağlanmasının en verimli yolu ise açık veri yaklaşımıdır. Demokratik rejimler, devlet yöneticilerinin kamu kurum ve kuruluşları eliyle yaptıkları harcamalara ilişkin verilerin yayınlanmasından, kamu kaynakları ile üretilen verilerin yeniden kamuya paylaşılmasını sağlamaya kadar pek çok alanda açık veriyi kullandığı görülmektedir. Açık veri yaklaşımının benimsenmesi, yönetimde şeffaflığa önemli katkılar sağlayacaktır. Açık verinin ülke yönetiminde kullanılması, literatürde Açık Hükümet (Open Government) olarak ifade edilmektedir (Hansson vd., 2014; Meijer, 2012) (Judie, 2015).

Kamu kaynaklarıyla üretilen veriler kamuya mâledilmelidir (Yıldırım, 2023). Kamu kaynağından kasıt, devlet yönetiminin topladığı vergilerdir. Kamudan toplanan vergiler yoluyla oluşturulan kaynakları kullanarak üretilen verilerin, açık veri lisans koşulları altında kamuya paylaşılması, demokratik yönetimlerin olmazsa olmaz şeffaflık ilkesine önemli katkılar sağlayacaktır. Kamu kurum ve kuruluşlarının hangi verileri açık veri olarak paylaşması gerektiği konusuna gelindiğinde, kişisel veriler ve ülke güvenliğini ilgilendiren veriler dışındaki tüm verilerin kamuya paylaşılması gerekmektedir. Kişisel veri içeren veriler dikkatli bir şekilde anonimleştirilerek paylaşılmalıdır. Ülke güvenliğini ilgilendiren veriler başlığında titiz bir çalışma yürütülmelidir.

Açık veri yaklaşımı, kamu kurum kuruluşları, özel sektör, yerel yönetimler ve veri ile iş yapan tüm kesimler arasındaki birlikte işlerliğe önemli katkılar sağlayacak ve bu sorunun hızlı bir şekilde çözümüne destek olacaktır. Kurumlar arasındaki birlikte işlerliğin sağlanması için çok sayıda yaklaşım ve çalışma olduğu görülmektedir. Örnek verecek olursak; ülkemizde konumsal verinin etkin bir şekilde paylaşılması için Konumsal Veri Altyapıları (KVA) konusunda uzun yıllardır çalışmalar yürütülmektedir (Cömert & Banger, 1996; Cömert, 2004; Cömert, 1998; Akıncı, 2006). Literatürde, KVA çalışmaları kapsamında, açık veri ekosisteminde mekânsal bağlantılı veri altyapılarına yönelik çalışma da bulunmaktadır (Günaydaş & Güney, 2019). 1995 yılından günümüze, ülkemizde çeşitli çalışmalar vesilesiyle KVA'nın tamamlanmasına çalışılmaktadır. Günümüzde bu çalışmalar, Çevre ve Şehircilik Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü koordinasyonunda yürütülmektedir. Yaklaşık 20 yıl boyunca kurumlar arasındaki birlikte işlerliği ve veri paylaşım sorununu çözme çalışmaları devam etmektedir. Henüz bu çalışmalar, kabul edilebilir bir seviyeye getirilememiştir. Açık veri yaklaşımı, KVA konusunda hızlıca bir çözüm üretilmesini sağlayacak bir yaklaşımdır. Ülke yönetiminde birlikte işlerlik mekanizmalarının kurulamaması, çeşitli kurum ve kuruluşların aynı veriyi tekrar tekrar üretmesine sebep olmaktadır. Açık veri yaklaşımının hayata geçmesiyle kurumlar ihtiyaç duyduğu veriye, açık kaynaklardan hızlıca erişim sağlayarak gereksiz maliyetlerden kurtulacaktır.

Açık veri yaklaşımı, inovasyon ve ekonomik büyümeye de oldukça önemli katkılar sağlamaktadır. McKinsey Global Enstitüsü, 2013 yılında yayınladığı bir raporda, 7 sektörde yıllık yaklaşık 3 trilyon ile 5 trilyon dolar arasında değerler ortaya çıkarılmasında yardımcı olabileceğini ifade etmektedir (Manyika vd., 2013). 2013 yılında Türkiye'nin Gayri Safi Yurt İçi Hasılası'nın (GSYİH) dünyanın tamamında üretilen GSYİH'e oranı 1.25 idi (The Global Economy.com, 2023). McKinsey raporunda açık veri ekosistemini hayata geçirilmesiyle ortaya çıkarılabilecek yıllık 3 trilyon ila 5 trilyon dolar arasında değeri bu oranla çarptığımızda, yıllık 3,75 milyar dolar ekstra değerler ülkemizde ortaya çıkabileceği görülmektedir. Açık veri, inovatif servisler ve uygulamaların geliştirilmesinin önünü açmaktadır (Jetzek, 2014; Eckartz, 2016; Yankova, 2016). Kurum verilerinin açık veri olarak yayımlanması, veri yayımlayıcısının sahip olduğu kaynaklar ile geliştiremeyeceği ve görev alanına girmeyen fakat çeşitli insanların hayatını kolaylaştıracak uygulamaların geliştirilmesinin önünü açmaktadır. Bu durum, yeni fırsatlar ve yeni potansiyelleri açığa çıkarmaktadır.

Açık veri, yeni girişimlerin önünü açarak ekonomik gelişime oldukça önemli katkılar sağlamaktadır. Günümüzdeki teknolojik gelişmeler incelendiğinde, birçok hizmetin internet üzerinden verildiği görülmektedir. Teknolojik tabanlı bir girişim için en önemli maliyet kalemlerinin içerisinde veriye erişim ve veri üretim maliyetlerinin olduğu görülmektedir. Açık veri, birçok girişimin en önemli maliyet kalemlerinden birisi olan veri üretim maliyetini oldukça düşürerek, bu kaynakların teknolojik gelişime ve ticari gelişime ayrılmasının önünü açmaktadır. Özel şirketler için açık veri yaklaşımı, yeni fırsatlar yaratmaktadır. Dünya genelinde açık veri yaklaşımını hayata geçirmiş ülkeler incelendiğinde, açık veri tabanlı yeni iş modellerinin hayata geçtiği görülmektedir (Wocken, 2022).

Açık veri yaklaşımı, ülke ve kent yönetimlerinde şeffaflığa katkı vermesinin yanı sıra hesap verilebilirlik ve denetlenebilirlik ilkesine de önemli katkılar sağlamaktadır. Denetlenebilirlik ve hesap verilebilirlik ilkeleri demokratik yönetim şeklinin olmazsa olmaz parçalarıdır. İlgili yöneticilerin kamu kaynaklarını nereye harcadıklarının denetlenmesi konusunda açık veri yaklaşımı oldukça önemli katkılar sunmaktadır.

4. Mevcut Açık Veri Çalışmalarının İrdelenmesi

Dünya genelinde yapılan açık veri çalışmalarında, pek çok ülkenin, kentin ve sivil toplum kuruluşlarının açık veri portal uygulamalarını hayata geçirdiği görülmektedir (Tablo 3).

Tablo 3. Açık veri portal uygulamalarından bazı örnekler

Sıra No	Açık Veri Portalı	Erişim Adresi
1	Dünya Bankası Açık Veri Portalı	https://data.worldbank.org/
2	Afrika Açık Veri Portalı	https://africaopendata.org/
3	Avrupa Birliği Açık Veri Portalı	https://data.europa.eu/en
4	Amerika Birleşik Devletleri Açık Veri Portalı	https://data.gov/
5	Birleşik Krallık Açık Veri Portalı	https://www.data.gov.uk/
6	Fransa Açık Veri Portalı	https://www.data.gouv.fr/
7	Almanya Açık Veri Portalı	https://www.govdata.de/
8	İspanya Açık Veri Portalı	https://datos.gob.es/
9	Litvanya Açık Veri Portalı	https://data.gov.lt/
10	Arjantin Açık Veri Portalı	https://www.datos.gob.ar/
11	Japonya Açık Veri Portalı	https://www.data.go.jp/?lang=en
12	Birleşik Arap Emirlikleri	https://bayanat.ae/en/Data
13	Amsterdam Açık Veri Portalı	https://data.amsterdam.nl/
14	New York Açık Veri Portalı	https://opendata.cityofnewyork.us/
15	Paris Açık Veri Portalı	https://opendata.paris.fr/pages/home/
16	Londra Açık Veri Portalı	https://opendata.london.ca/
17	Dünya Sağlık Örgütü Açık Veri Portalı	https://data.who.int/
18	Birleşmiş Milletler Açık Veri Portalı	https://data.un.org/

Ülkemizde açık veri çalışmalarının yakın dönemde hızlandığı görülmektedir. Ülkemizde yayınlanan açık veri portal uygulamalarının son 3 yılda hayata geçtiği görülmektedir (Tablo 4).

Tablo 4. Türkiye’de gerçekleştirilen açık veri çalışmalarının listesi

Sıra No	Portal Yazılımı	Erişim Adresi
1	İstanbul Büyükşehir Belediyesi Açık Veri Portalı	https://data.ibb.gov.tr/
2	İzmir Büyükşehir Belediyesi Açık Veri Portalı	https://acikveri.bizizmir.com/
3	Ankara Büyükşehir Belediyesi Açık Veri Portalı	https://seffaf.ankara.bel.tr/
4	Konya Büyükşehir Belediyesi Açık Veri Portalı	https://acikveri.konya.bel.tr/

Tablo 4'ün devamı

Sıra No	Portal Yazılımı	Erişim Adresi
5	Balıkesir Büyükşehir Belediyesi Açık Veri Portalı	https://acikveri.balikesir.bel.tr/
6	Küçükçekmece Açık Veri Portalı	https://acikveri.kucukcekmece.bel.tr/
7	Marmara Belediyeler Birliği Açık Veri Portalı	https://data.marmara.gov.tr/
8	Gaziantep Büyükşehir Belediyesi Açık Veri Portalı	https://acikveri.gaziantep.bel.tr/
9	Ordu Büyükşehir Belediyesi Açık Veri Portalı	https://acikveri.ordu.bel.tr/
10	Ulusal Akıllı Şehir Açık Veri Portalı	https://ulasav.csb.gov.tr/
11	Ulusal Coğrafi Açık Veri Portalı	https://tucbskontrol.csb.gov.tr/TUCBSAcikVeri

Ülkemiz genelinde yapılan açık veri çalışmaları incelendiğinde, çoğunlukla yerel yönetimler düzeyinde açık veri uygulamalarının hayata geçtiği görülmektedir. Yapılan incelemeler sonucunda, hayata geçirilen tüm bu açık portal altyapılarının açık veri ekosistemi için oldukça değerli olmasıyla beraber, henüz başlangıç seviyesinde olduğu görülmektedir. Diğer taraftan, yayınlanan veri setlerinin katma değerinin düşük seviyede olduğu görülmektedir. Açık veri ekosisteminin genişlemesi ve çok daha fazla sayıda insanın haberdar olması ve açık veriyle iş yapabilme alışkanlığının kazanılması için etkisi yüksek ve üretilmesi maliyetli verilerin açık veri haline getirilmesi önemli katkılar verecektir. Mevcutta yayın hayatına geçmiş açık veri portallarının sürdürülebilir olması için bu doğrultuda gerekli çalışmaların yapılması gerekmektedir.

İstanbul Büyükşehir Belediyesi ve İzmir Büyükşehir Belediyesi tarafından yayınlanan açık veri portallarında kullanılan açık veri lisanslarını incelediğimizde her kurumun belli bir açık veri lisansını temel alarak kendi açık veri lisansını yayınladıkları görülmüştür. Bu yaklaşım, açık veri lisansları açısından yanlış değil fakat tavsiye edilmeyen bir yaklaşımdır. Çünkü; son kullanıcı karşılaştığı her farklı açık veri lisansında, lisans koşullarını incelemek zorunda kalmaktadır. Halbuki, bu açık veri lisansları incelendiğinde, CC BY 4.0 lisansının koşullarını işlettiği görülmektedir. Dolayısıyla, her belediye kendi ismiyle bir açık veri lisansı oluşturmak yerine kullanılan açık veri lisansını CC BY 4.0 olarak bildirmesi durumunda, son kullanıcının açık veri lisansını inceleme gerekliliği ortadan kaldırılabilir. Tablo 4'te listelenen tüm açık veri portallarında, veri setlerine metaveri belgelerine XML (Extensible Markup Language) formatlarında erişim sağlanamamaktadır. Ayrıca açık veri portallarının çoğu, açık kaynak kodlu açık veri platformu olan CKAN platformunu kullanması ve kullanılan platformun servis API'leri olmasına rağmen, API bilgilerinin hiçbir platformda kullanıcıyla doğrudan paylaşılmadığı görülmektedir. Ayrıca, sistemlerde kullanılan metaveri standardı hakkında herhangi bir bilgi paylaşılmamıştır. İlgili açık veri portal çalışmalarında; servis API bilgilerinin paylaşımı ve kullanılan metaveri standardı hakkında bilgiler verilmesi daha sağlıklı bir açık veri altyapısının oluşturulması için önemli katkılar sağlayacaktır.

Ankara Büyükşehir Belediyesi, açık veri platformu olarak yayınlanan uygulamada, çeşitli verilerin indirilebilir şekilde yayımlandığı görülmektedir. Fakat bu verilerin hangi açık veri lisansı koşulları altında yayımlandığı belirsizdir. Ayrıca veri seti hakkında verilen bilgilerin oldukça yetersiz olduğu görülmektedir. Veri ismi ve veriyi yayınlayan birim dışında veri seti hakkında herhangi bir bilginin kullanıcıya sunulmadığı görülmektedir. Burada kullanılan metaveri standardının ne olduğu konusunda herhangi bir bilgiye erişim sağlanamamıştır. Veri seti yayınlanma yaklaşımına bakıldığında, aynı veri setine ilişkin farklı yıllara ait verilerin ayrı ayrı veri seti olarak yayımlandığı görülmektedir. Bu yaklaşım, veriye erişimin kolaylaştırılması açısından olumsuz bir örnek teşkil etmektedir. Dünya genelinde, yıllara göre farklılık gösteren verilerin tek bir veri seti olarak yayımlandığı her yıl için ayrı ayrı indirme bağlantısının ilgili veri setine eklendiği görülmektedir.

Marmara Belediyeler Birliği ile Gaziantep Büyükşehir Belediyesinin açık veri portalları incelendiğinde, bu portalların hangi açık veri lisans koşulları altında yayımlandığının belirsiz olduğu görülmektedir. Bu durum, açık veri yaklaşımının ana ilkelerinden birisi olan açık veri lisans koşulu altında yayınlanması durumuna uyumlu değildir. Bu portal uygulamalarında verilere ilişkin açık veri lisansı belirlenmeli ve kullanıcılar ile paylaşılmalıdır.

Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından yayınlanan Ulusal Coğrafi Açık Veri Portal uygulaması incelendiğinde, öncelikle verilerin hangi açık veri lisans koşulu altında yayımlandığının belirsiz olduğu görülmektedir. Öncelikle, hangi açık veri lisans koşulu altında yayımlandığı belirlenmeli ve ilgili platformda kullanıcıya bilgilendirme yapılmalıdır. Açık veri portalı; 246 adet veri seti, 198 adet WMS (Web Map Service) servisi, 31 adet WMTS (Web Map Tile Service) servisi, 16 adet WFS (Web Feature Service) ve 1 adet WCS (Web Coverage Service) servisinden oluşmaktadır. Yayınlanan veriler, *yeniden kullanım ve yeniden dağıtım* ilkesi doğrultusunda incelendiğinde, CBS (Coğrafi Bilgi Sistemleri) Genel Müdürlüğü açık veri portal uygulamasında açık veri olarak kabul edilebilecek 17 adet veri seti olduğu

görülmektedir. CBS Genel Müdürlüğü tarafından yayınlanan Atlas isimli uygulamada açık veri kullanıcı tipinde bir giriş ekranı olduğu için bu çalışma kapsamında açık veri portalı olarak değerlendirmeye alınmıştır. Atlas uygulamasında bir açık veri girişi ekranı olduğu görülmektedir. Bu açık veri girişi ekranı ile sisteme girildiğinde, TUCBS (Türkiye Ulusal Coğrafi Bilgi Sistemi) arama ekranında belirli kategorilerde metaveri listesinin yayınlandığı görülmektedir. Bu metaveri listesi incelendiğinde, açık veri kullanıcısının erişimine açık, sadece 1 adet WFS servisi olduğu tespit edilmiştir. Diğer tüm verilerin WMS servisi olduğu görülmektedir. Dolayısıyla, açık veri olarak nitelenebilecek 1 adet veri setinin olduğu görülmektedir. WFS servisi olarak yayınlanan bu veri seti incelendiğinde aktif olarak çalışmayan bir veri seti bulunmaktadır.

Açık veri kullanıcısı ile sisteme giriş yapıldığında seçilen bir verinin görüntülenmesi esnasında WMS servis isteği incelendiğinde _appToken parametresi ile istek gönderilebileceği görülmektedir. Bu _appToken parametresinin, kullanıcının açık veri kullanıcısı olarak sisteme giriş yapması sonrasında üretildiği anlaşılmaktadır. Dolayısıyla, Atlas uygulamasında yayınlanan herhangi bir verinin dışarıdan görüntülenebilmesinin mümkün olmadığı görülmektedir. Dolayısıyla hem verinin WMS olarak yayınlanması hem de paydaşların bu servisleri başka ortamlarda görüntülenmesi engellendiği için atlas uygulamasının bir açık veri platformu olarak nitelendirilmesinin mümkün olmadığı anlaşılmaktadır.

Mevcut açık veri portal çalışmaları yanı sıra Türkiye'nin 2011 yılında, ABD Başkonsolosluğu aracılığıyla Açık Devlet Ortaklığına katılım sağladığı görülmektedir. Açık Hükümet Ortaklığı (OGP), şeffaflığı teşvik etmek, sivil katılımı artırmak, yolsuzlukla mücadele etmek ve hükümetleri dünya genelindeki vatandaşlara karşı daha açık, etkili ve hesap verebilir kılmak için ve yeni teknolojilerden yararlanmak için hükümetlerden somut taahhütler almayı amaçlayan bir girişim olduğu görülmektedir. Ülkemiz OGP'ye katıldığını duyurduktan sonra 2016 yılında gerekli aksiyonların alınmamasından dolayı üyelikten çıkarıldığı görülmektedir. Dünya genelinde açık veri çalışmaları incelendiğinde, bu açık veri çalışmalarını puanlayan çeşitli puanlama ve sıralama çalışmaları olduğu görülmektedir. Türkiye'nin, Open Data Watch listesinde 192 ülke arasında 59. sırada olduğu, Global Open Data Index listesinde 94 ülke arasında 45. sırada ve Open Data Barometer listesinde 114 ülke arasında 37. sırada olduğu görülmektedir. Bu sıralamalara bakıldığında, ülkemizin açık veri çalışmalarını hızlandırması gerektiği görülmektedir.

4.1. OGC (Open Geospatial Consortium) Web Map Service (WMS) / WMTS (Web Map Tile Service) Servisi, açık veri paylaşım yöntemi olarak kabul edilebilir mi?

WMS ve WMTS servisleri, OGC tarafından yayınlanan web servisleri standartlarıdır. WMS ve WMTS servisleri, konumsal veri görüntüleme servisleridir. OGC WMS/WMTS servisleri temel olarak bir coğrafi verinin web servisi üzerinden resim olarak gösterimini sağlayan bir web servisedir. Verinin indirilmesi hizmetini bu servisler sağlamamaktadır. Dolayısıyla, bir veri setinin sadece WMS veya WMTS servisleri yoluyla yayınlanması, o veri setinin açık veri olarak kabul edilmesi için yeterli değildir. WMS servisleri ve WMTS servisleri yoluyla yayınlanan veri setleri açık veri olarak kabul edilemez. Çünkü açık veri koşullarından kullanılabilirlik ve erişilebilirlik, yeniden kullanılabilirlik ve yeniden dağıtım ilkelerini ihlal eden bir yöntemdir (Tablo 5).

4.2. Kent Rehberi, İmar Durumu ve Mezarlık Bilgi Sistemi vb. uygulamaları, açık veri paylaşım yöntemi olarak kabul edilebilir mi?

Özellikle yerel yönetimlerde kent rehberi, imar durumu ve mezarlık bilgi sistemi gibi web uygulamalarının vatandaşların kullanıma açıldığı görülmektedir. Bu uygulamalarda kullanıcılar web uygulamaları üzerinde kente dair çeşitli sorgulamalar yaparak bilgi öğrenme işlemlerini gerçekleştirebilmektedir. Bu tarz web uygulamaları, konumsal verinin görüntülenmesi hizmetini vermektedir. Dolayısıyla, kullanılabilirlik ve erişilebilirlik, yeniden kullanılabilirlik ve yeniden dağıtım, açık ve makine tarafından okunabilir format, evrensel erişim ve açık veri lisans koşullarını ihlal etmektedir (Tablo 5).

Bu uygulamaların açık veri yaklaşımına uygun olduğunu söylenebilmesi için uygulama bünyesinde kullanıcılara sorgulanmasına izin verilen tüm verilerin indirilebilir ve açık veri koşullarının tamamını sağlayacak şekilde yayınlanmalıdır.

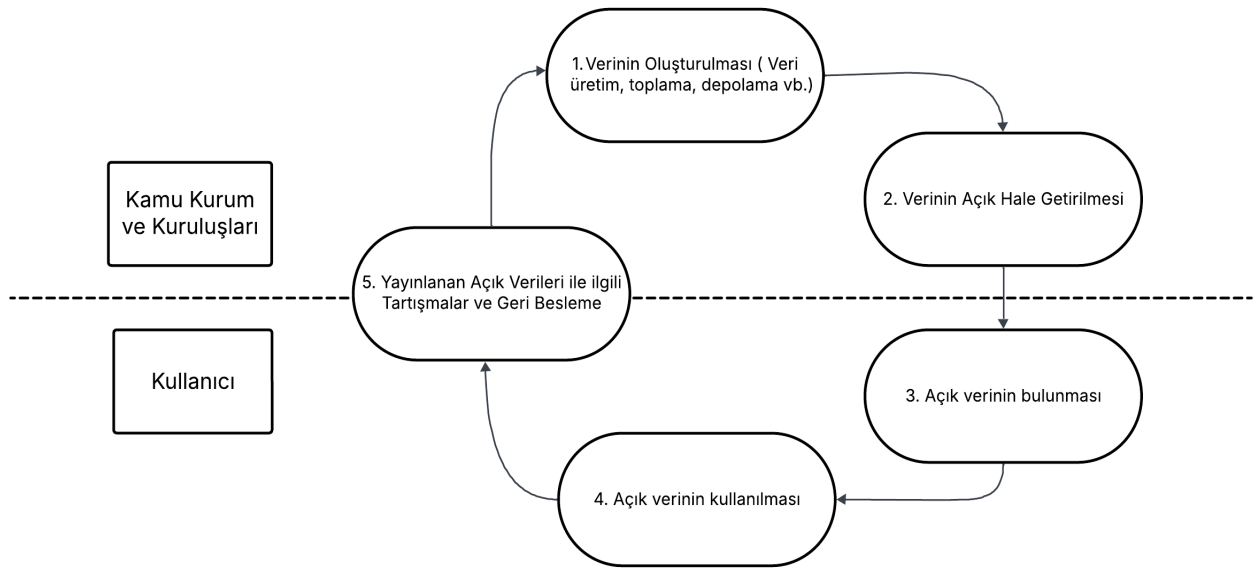
Tablo 5. OGC WMS Servisi ve web uygulamalarının açık veri koşulları bakımından irdelenmesi

Veri Yayınlama Yöntemi	Kullanılabilirlik ve erişilebilirlik	Açık ve Makine Tarafından Okunabilir Format	Yeniden kullanım ve yeniden dağıtım	Evrensel erişim	Açık veri lisans
OGC WMS Servisi	×	✓	×	✓	✓
Web Uygulamaları	×	×	×	×	×

5. Kamu Kurumlarının Açık Veriye Geçiş Yol Haritasının Oluşturulması

Bu çalışma kapsamında, açık veri ekosistemini hayata geçirmek isteyen bir kurumun, açık veriye geçiş yol haritasının oluşturulmasına yönelik çalışmalar gerçekleştirilmiştir. Açık veriye geçişin kurumların açık kaynak kodlu bir portal yazılımını bir sunucuya kurması ve kurumun web sayfasında bir linkten yayınlanması ile tamamlanacak bir çalışma olmadığı açıktır. Açık veri çalışmaları, belirli bir vizyon doğrultusunda belirlenecek kısa ve uzun vadeli hedefler doğrultusunda hayata geçirilmelidir. Literatür de açık veri ekosistemini hayata geçirilmesine yönelik çeşitli çalışmalar bulunmaktadır (Zuiderwijk, 2012; Dawes vd., 2016). Dawes vd. (2016)'da açık veri ekosistemini sosyal ve teknik bileşenleri yönünden incelemiştir. Bunlar; veri odaklı yaklaşımlar, program odaklı yaklaşımlar, kullanım ve kullanıcı odaklı yaklaşımlar, puan kartı ve etki (impact) odaklı yaklaşımlar, ağ ve ekosistem odaklı yaklaşımlar şeklindedir.

Zuiderwijk (2012)'e göre açık veri süreci 5 ana başlıkta gruplandırılmaktadır. Bunlar; verinin oluşturulması, verinin açık hale getirilmesi, açık verinin bulunması, açık verinin kullanılması ve yayımlanan açık veri üzerinde tartışmalar ve veri yayıncısına geri besleme verilmesidir (Şekil 1).



Şekil 1. Açık veri süreci (Zuiderwijk, 2012)

Zuiderwijk (2012)'e göre açık veri yaklaşımında, 3 farklı düzeyde kategorilendirme yoluna gidilmektedir. Bunlar; veri yayıncısı düzeyi, veri kullanıcısı düzeyi ile araç ve servisler düzeyi şeklindedir (Zuiderwijk, 2012). Bu çalışmada, veri yayıncısı düzeyinde yapılması gerekenler, veri kullanıcısının yapabileceği işlemler ve açık veri ekosisteminde sağlanması gereken araçlar ve hizmetler konusunda kategorilendirme yapılmıştır (Zuiderwijk, 2012). Jetzek (2016)'da, açık veri ekosistemi çalışmalarını, stratejik, ekonomik, hukuki ve teknik olarak 4 farklı kategoride incelemiştir. Bu çalışmaların dışında, literatürde açık veri çalışmalarının teknik boyutuna değinen oldukça fazla sayıda çalışma bulunmaktadır (Judie vd., 2015; Umbrich vd., 2015; Nayek, 2018; Wenige vd., 2021; Goodey vd., 2022). Literatürde açık veri yaklaşımının hayata geçirilmesinin kısmi yönleri ele alınmıştır. Bu çalışma kapsamında, açık veri çalışmalarına yol gösterecek daha kapsayıcı bir yol haritası oluşturulması hedeflenmiştir. Kurumların açık veri çalışmalarının 5 ana başlık altında yönetilmesine karar verilmiştir. Bu başlıklar; teknik çalışmalar, politika ve yasal çalışmalar, finansal çalışmalar, organizasyonel çalışmalar ve kültürel çalışmalar şeklinde sınıflandırılmıştır.

5.1. Teknik Çalışmalar

Açık veri çalışmalarında; kullanılacak teknolojik altyapı, metaveri standardı, veri formatları ve sistem mimarisi gibi konularda faaliyetler yürütülmelidir. Açık veri çalışmalarında, dünya genelinde kabul görmüş açık veri paylaşım yöntemi olan açık veri portal altyapısı yayınlanmasının hedeflenmesi durumunda, kullanılacak açık veri portal yazılım altyapısının seçilmesi gibi konularda çalışmalar yürütülmelidir.

Açık veri portalının yayınlanmasında kullanılacak donanım altyapısı için gereksinim analiz çalışmaları yapılmalıdır. Bu gereksinim analizi çalışmalarında, yayınlanacak açık veri portalında, veri hacmi, potansiyel kullanıcı sayısı, web trafiği gibi konularda çalışma gerçekleştirilmelidir. Bu çalışma sonucunda donanım altyapısı gereksinimleri belirlenmelidir.

Metaveri standardı ve sistem mimarisi, açık veri portal platformu olarak kullanılacak yazılımının seçilmesinden sonra değişiklik göstereceğinden, donanım altyapısı seçildikten sonra yazılım altyapısı seçilmelidir. Açık veri portalının yazılım altyapısı için açık kaynak kodlu ve ticari lisanslı birçok seçenek bulunmaktadır. Dünya genelinde, CKAN, Socrata, OpenDataSoft, DKAN, ArcGIS Open Data, Junar gibi açık veri portal yazılımları mevcuttur. Diğer taraftan, hazır portal yazılımları dışında, sıfırdan kod geliştirerek açık veri portal yazılımı hayata geçirilebilmektedir. Sıfırdan kod geliştirme yapılırken dikkat edilmesi gereken bazı hususlar bulunmaktadır. Bu durumda; servis altyapısının tasarımı, servis dokümantasyonu ve kullanılacak metaveri standardı önem arz etmektedir.

Sıfırdan kod geliştirme süreçlerinde ana hedef, veriye erişimi kolaylaştırmak olmalıdır. Dolayısıyla, arayüzün kullanıcı dostu olmasının yanı sıra, servis API tasarımının geliştiriciler tarafından kolay anlaşılabilir ve uygulanabilir olması gerekmektedir. Servis dokümantasyonu açık veri portalı arayüzünde yayınlanmalıdır. Açık veri portalında kullanılacak metaveri standardı konusunda herhangi bir zorunluluk olmamakla birlikte, dünya genelinde yapılan çalışmalar incelendiğinde literatürde kabul görmüş metaveri standartları üzerinde genişletme yapılarak ihtiyaçlara göre bir metaveri standardı belirleme yoluna gidilmektedir. Literatürde kabul görmüş metaveri standartlarını referans alarak, Uygulama Profili (Application Profile) belirleme yoluna gidilebilir. Bu yaklaşıma, Amerika Birleşik Devletleri açık veri portal uygulamasında kullanılan, DCAT-US Schema v1.1 metaveri standardı (Data.gov, 2014), Avrupa Birliği Açık Veri Portal Projesinde kullanılan DCAT-AP For EU Open Data Portals v2.1.1 metaveri standardı (European Commission, 2013) örnek olarak gösterilebilir.

Herhangi bir metaveri standardı temel alınarak belirlenmeyen ve sıfırdan oluşturacağınız metaveri standardı, verinin ulaşılabilirliğine önemli dezavantajlar getirecektir. Açık veri portalı aynı zamanda geliştiricilere sağlayacağınız API sayesinde metaveri üzerinden arama, metaveri harvesting gibi birçok işlemi gerçekleştirilebilmesi, erişilebilir açık veri ekosistemi yaratılması açısından oldukça önemlidir. Açık veri konusunda çalışan geliştiricilerin literatürde kabul görmüş standartlara aşina olması, işleri daha da kolaylaştırmaktadır. Kendi metaveri standardınızı geliştirdiğiniz senaryoda, geliştirici yayınladığınız metaveri standardını öğrenmek için ekstra zaman harcayacaktır. Bu durum erişilebilirlik açısından, oluşturulması hedeflenen açık veri ekosistemine zarar verecektir. Metaveri standardı belirleme çalışmalarında temel alabileceğiniz bazı metaveri standartları mevcuttur. Bunlar; DCAT, Dublin Core, CKAN, Socrata, INSPIRE, ISO 19115 ve ISO 19119 şeklinde sıralanabilir. Açık veri portallarını incelendiğinde yoğunlukla kullanılan DCAT, CKAN ve Dublin Core metaveri standartlarıdır. Bu metaveri standartları üzerinde bir uygulama şeması geliştirilerek ya da en hızlı ve kolay yöntem olarak doğrudan mevcut sistemlerde aktif kullanılan metaveri standartlarından birisi tercih edilebilir.

Yayınlanacak verinin açık veri olarak kabul edilebilmesi için bir açık veri lisans koşulları altında yayınlanması gerekmektedir. Açık veri platformunda, Tablo 1 de gösterilen açık veri lisanslarından birisi veya birkaçı yayınlanacak açık veriler için veri lisansı olarak kullanılabilir. Açık veri lisansları, kendi hüviyeti gereği açık kaynak kodlu lisanslardır. Bu durumda, isteyen kullanıcılar açık veri lisanslarını, lisanslarda yayınlanan koşulları devre dışı bırakmamak kaydıyla kendi açık veri lisanslarını üretebilmektedir. Ülkemizde yayına alınan her açık veri portalında yayınlanan açık veri lisansları, bu duruma örnek olarak gösterilebilir. İstanbul Büyükşehir Belediyesi açık veri portalında, İstanbul Büyükşehir Belediyesi Açık Veri Lisansı, İzmir Büyükşehir Belediyesi açık veri portalında, İzmir Büyükşehir Belediyesi Açık Veri Lisansı yayınlanmıştır. Bu durum çeşitli dezavantajlar yaratmaktadır. Ülkemizde, 81 il belediyesi ve 922 ilçe belediyesi bulunmaktadır. Tüm belediyelerin açık veri portalını hayata geçirmesi senaryosunda, ülkemizde belediyeler eliyle 1003 adet açık veri portalı yayına alınacaktır. Her belediyenin kendi açık veri lisans tanımını yaptığı durumda 1003 adet farklı açık veri lisansı ortaya çıkacaktır. Bir verinin açık veri olarak tanımlanması için en önemli bileşenlerden birisi açık veri lisansıdır. Bu durumda açık veri kullanıcısı, aşına olduğu açık veri lisanslarının dışında bir açık veri lisans tanımıyla karşılaştığında ilgili verinin kullanım koşullarını anlamak için ilgili lisans koşullarını incelemek zorunda kalacaktır. 1003 adet farklı açık veri lisansının yayınlanması senaryosunda, açık veri kullanıcısının incelemesi gereken 1003 farklı açık veri lisansı ortaya çıkacaktır. Ülkemizde gerçekleştirilen açık veri çalışmalarında belirlenen farklı açık veri lisanslarının yarattığı sorun, literatürde kabul görmüş açık veri lisanslarının olduğu gibi kullanılmasıyla ya da ülke genelinde açık veri çalışmaları için yayınlanacak bir açık veri lisansının kullanılmasıyla hızlı bir şekilde çözülebilecektir.

Açık veri portalında kullanılacak açık veri formatlarının belirlenmesi çalışması yapılması gerekmektedir. Kullanılacak açık veri formatları, veriye erişimi kolaylaştıracak veri formatları olmalıdır. Tablo 6'da örnek olması açısından, açık veri formatlarından bazıları listelenmiştir. Kurum bünyesinde açık veri olarak yayınlanabilecek verilere yönelik envanter oluşturulması çalışması yürütülmelidir. Açık veriye yönelik envanter çalışmasında kurum bünyesinde üretilen veriler ile ilgili bilgiler toplanırken, ilgili veriyi üreten birim, veri sorumlusu, güncelleme aralığı, veri formatı gibi bilgiler toplanmalıdır. Bu çalışma, hayata geçirilmesi planlanan açık veri ekosistemi için hayati olsa da aynı zamanda bu çalışmaları yapan kurumlar için de oldukça önemli katkılar sunacaktır. Çoğunlukla kurum ve kuruluşlarda, kurum bünyesinde ilgili birimlerde üretilen veriler ile ilgili bilgi eksikliği, tekrarlı veri üretimine sebebiyet vermektedir. Kurum içerisinde üretilen verilere ilişkin hazırlanacak envanter raporu, kurumların kendi iç birimlerindeki birlikte işlerlik mekanizmalarına da önemli katkı sağlayacaktır. Envanter raporu oluşturulduktan sonra, belirlenecek açık veri strateji ve eylem planlarına göre öncelikli alanlar belirlenmelidir.

Tablo 6. Açık veri formatlı olarak kullanılabilen örnek açık veri format listesi

Format Adı	Açıklama
CSV	Virgülle ayrılmış sınırlanmış metin dosyasıdır. Açılımı; <i>comma separated values</i>
RDF	Açılımı; <i>resource description framework</i> , kaynak tanımlama çerçevesi. Bağlantılı veri kapsamında kullanılan veri formatıdır.
JSON	Açılımı; <i>Javascript Object Notation</i> , RFC-8259 standardıyla tanımlanmıştır. REST servislerinde en sık kullanılan veri formatıdır.
XML	Açılımı; <i>Extensible Markup Language</i> . W3C tarafından Extensible Markup Language ismiyle standart olarak yayınlanmıştır. SOAP servislerinde sıklıkla kullanılan bir formattır.
ODF	Açılımı; Open Document Format, OASIS tarafından standart olarak yayınlanmıştır. Microsoft Word vb. yazılımların metin ve diğer işlemler için kullanılan açık bir veri formatıdır.
GeoJSON	Açılımı; Geographical Javascript Object Notation, JSON veri formatının konumsal veriler için oluşturulan formattır. RFC-7946 standardıyla tanımlanmıştır.
GML	Açılımı; Geographical Markup Language, XML veri formatının konumsal veriler için oluşturulan formattır. ISO 19136:2007 standardıyla tanımlanmıştır.
KML	Açılımı; Keyhole Markup Language, Google tarafından XML genişletilerek oluşturulan bir uygulama profilidir. İlk defa Google Earth programı tarafından kullanıldı. Daha sonra bir OGC standardı haline gelerek açık veri formatı oldu.
WKT	Açılımı; Well Known Text, metin tabanlı vektör geometrileri için oluşturulmuş bir veri formatıdır.
LAS	Açılımı; Laser veri formatı, Lidar nokta bulutu verilerinin saklanması ve farklı veri formatları arasında dönüşüm için oluşturulmuş veri formatıdır.
Shapefile	CBS yazılımları tarafından kullanılan konumsal vektör veriler için oluşturulmuş veri formatıdır.
Geotiff	CBS yazılımları tarafından sıkça kullanılan bir raster veri dosya formatıdır.

Açık veri strateji eylem planlarında belirlenecek öncelikli alanlar, yayınlanacak veri setlerinin etkisine (impact) göre belirlenmelidir. Bir açık veri setinin yayınlanmasında, ilgili verinin sağlayacağı katma değer belirlenmesi önemlidir. Açık veri çalışmaları incelendiğinde, açık verinin etkisi çeşitli kategoriler altında değerlendirildiği görülmektedir (European Union, 2021; Open Data Barometer, 2023; Verhulst & Young, 2017; Ooijen vd., 2023). Avrupa Birliği Açık Veri Portalı tarafından yayınlanan Açık veri olgunluk raporunda açık veri etkisi, sosyal etki, politik etki, ekonomik etki ve çevresel etki olarak 4 farklı kategoride değerlendirilmiştir (European Union, 2021). Açık veri olgunluk modeli rapor çalışması sonucunda, Avrupa Birliği Açık Veri Portalında her yıl için, yayınlar başlığı altında açık veri olgunluğu raporu olarak paylaşılmaktadır (European Union, 2022a). Open Data Barometer (ODP), tarafından belirlenen açık veri etki değeri belirlemedeki kategoriler, sosyal, politik ve ekonomik etki olarak 3 farklı kategoride değerlendirilmektedir (Open Data Barometer, 2023). Verhulst ve Young tarafından 2017 yılında yazılan gelişen ekonomilerde açık veri isimli yayında, yönetimin iyileştirilmesi, vatandaşların güçlendirilmesi, ekonomik fırsatların yaratılması, kamusal problemlerin çözülmesi olarak 4 farklı kategoride açık verinin etkisi incelenmiştir. Bu çalışmaların dışında, açık verinin etkisini tanımlaya yönelik çeşitli çalışmalar literatürde bulunmaktadır (Kawashita vd., 2020; Sussha vd., 2015; Krishnamurthy & Awazu, 2016; Apanasevic, 2021; Lokers vd., 2019; Shaharudin, 2020; Corrales-Garay vd., 2020). Bu çalışmalar dışında, Ooijen vd. (2023)'te Avrupa Birliği açık veri portal çalışmaları kapsamında açık veri etkisine yönelik araştırma çalışmasında, Avrupa Birliğine bağlı ülkelerdeki açık veri çalışmalarında açık veri etkisinin nasıl ölçüldüğüne dair çalışmalar yapıldığı görülmektedir. Bu çalışmalar incelendiğinde, açık veri portallarında, açık verinin yeniden kullanıldığı kullanım senaryoları ve çeşitli metrikler ile açık veri etkisinin ölçülmeye çalışıldığı görülmektedir. Açık verinin etkisinin ölçülmesi için belirlenen metriklere, Avusturya açık veri çalışmaları örnek olarak gösterilebilir (<https://www.data.gv.at/infos/analyse/>).

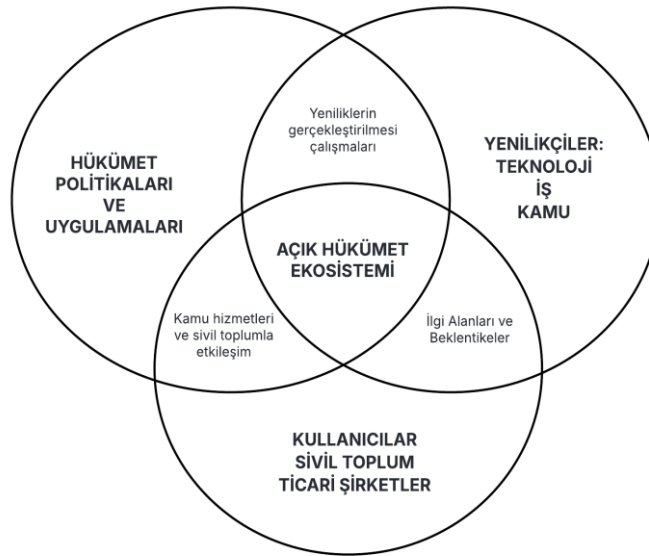
Avusturya Açık Veri Etki Değerlendirmesi Metrikleri:

1. Ziyaretçi Sayısı
2. İndirilme Sayısı
3. Açık verilerin kullanım talebi ve sıklığı,
4. Açık veri yayıncı sayısı
5. Açık veri kullanılarak yayınlanan uygulama sayısı

Açık veri çalışmalarına başlamamış veya yeni başlayan kurumların, etkisi yüksek açık veri setlerini belirlemek için açık veri çalışmalarında iyi bir seviyeye ulaşmış ülkelerdeki açık veri portal çalışmalarını inceleyip, Avusturya örneğinde kullanılan metrikler ile etkisi yüksek açık veri setlerini belirleme çalışmaları yürütülmelidir. Avrupa Birliği açık veri portal çalışmasında belirlenen yüksek katma değerli ana kategorilerden birisinin konumsal veriler olduğu görülmektedir (European Union, 2022b). Konumsal veriler ana kategorisinin, alt kırılımların bakıldığında, İdari Sınırlar, Coğrafi Yer İşaretleri, Adres, Bina, Kadastro parseli gibi veri setleri yüksek katma değerli veriler olarak ifade edilmiştir.

5.2. Politika ve Yasal Çalışmalar

Açık veri ekosistemi, sadece kamu kurum ve kuruluşlarındaki yöneticiler tarafından alınacak bir karar ile yayına alınacak açık veri portalı ve bu portalda çeşitli açık verilerin yayınlanması ile hayata geçirilemez. Açık veri ekosisteminin oluşturulması için Şekil 2’de görüldüğü gibi sadece verilerin yayınlandığı bir açık veri portalı tek başına yeterli değildir. Bunun yanı sıra girişimciler, üniversiteler ve vatandaşlar vb. birçok taraf ile yaşayan bir ekosistemin oluşturulması gerekmektedir.



Şekil 2. Açık veri ekosistemi (Harrison, 2012)

Açık veri konusunda yürütülecek teknik çalışmaların yanı sıra açık verinin sahip olduğu katma değeri ortaya çıkaracak bir ekosistemin oluşturulması ana hedeflerden birisi olmalıdır. Bu ekosistemin yaratılması için karar vericilerin politik ve yasal çalışmalar yapması gerekmektedir.

Açık veri etrafında oluşturulacak politika, açık yönetim şekli, şeffaflık, hesap verilebilirlik, ekonomik gelişim, vatandaşların hayatını kolaylaştırmak üzerine olmalıdır. Bu politika bir vizyon belgesi ve strateji dokümanları ile açıklanmalıdır. Politik çalışmalar kapsamında, açık veri çalışmalarından sorumlu bir birim oluşturulması ve bir açık veri liderinin görevlendirilmesi önemli katkılar sağlayacaktır. Açık veri süreçlerini yönetecek sorumlu birimin oluşturulması, açık veri projesinin sahiplenilmesi ve sürdürülebilir bir şekilde hayatına devam etmesi açısından oldukça önem arz etmektedir. Açık veri ekosisteminin hayata geçirilmesinden sorumlu olan kurumlar, vizyon ve strateji belgelerini açıklamalıdır. Vizyon ve strateji belgelerini açıkladıktan sonra, bir yol haritası belirlenmelidir. Bu yol haritası titizlikle takip edilmelidir. Yapılacak envanter çalışması kapsamında öncelikli belirlenen alanlarda yayınlanacak verilerden sorumlu birimler ve kişiler belirlenmelidir. Sorumlu birim ve kişiler tarafından belirlenen veri güncellemesi zaman aralığına göre verilerin güncel tutulması sağlanmalıdır.

Açık veri çalışmalarında belirlenen sorumluluklar, kesinlikle resmi görevlendirmeler ile yapılmalıdır. Örneğin; açık veri portalını hayata geçirecek kurum bir belediye ise belediye meclisi bu görevlendirmeyi bir yönerge ile hayata geçirmesi,

veri sorumlularının çok daha proaktif davranmasına destek verecektir. Bu aşama tamamlandıktan sonra, ilgili kurum açık veri yayınlama prosedürünü belirlemesi ve şeffaf bir şekilde yayınlaması gerekmektedir. Açık veri portalında, gelişigüzel veri yayınlanmasının önüne geçilmelidir. Belirli kalite kriterlerini sağlayan, sorumlusu belli olan, belirli aralıklarla güncellenebilen ve yayınlanmasıyla yarattığı etkinin belirli bir seviyenin üzerinde olan verilerin paylaşılması hedeflenmelidir.

Açık veri ekosisteminde çözülmesi gereken en önemli problemlerden birisi olan açık verinin bulunabilmesi olduğu unutulmaması gerekir. Dolayısıyla, belirli bir prosedür yürütmeden verilerin açık veri olarak yayınlanması, etkisi ve kalitesi bakımından önemli olan verilerin son kullanıcı tarafından bulunabilmesini zorlaştıracaktır. Verilerin açık veri olarak yayınlanması veriye erişimin önündeki engelleri kaldırmaya tek başına yeterli değildir. Belli kurallara göre denetlenmiş verilerin yayınlanması, son kullanıcıların açık verilere kolayca erişebilmesine katkı sağlayacaktır.

5.3. Finansal Çalışmalar

Finansal çalışmalar başlığı altında yapılacak çalışmaların ana hedefi, hayata geçirilecek açık veri ekosisteminin sürdürülebilir kılınmasıdır. Dolayısıyla, açık veri portal uygulaması yayınlanması ve uzun vadeli hayatta tutulabilmesi için kurum tarafından bütçe tanımlanması yapılmalıdır. Açık veri portal uygulamasını sürdürülebilir kılmak için kurulacak birim ve çalışanların finansmanı belirlenmelidir.

Açık veri çalışmalarında, kurumlarda açık veri ekosisteminin hayata geçirilmesi ve sürdürülebilir kılınmasıyla sorumlu bir birimin oluşturulması gerekmektedir. Bu birimin tek görevinin bu sistemi hayata geçirmek, sürdürülebilir kılması ve bu sistem etrafında paydaşlar ile çeşitli aktiviteler ile açık veri ekosistemini yaşayan canlı bir ekosistem haline getirmek olmalıdır. Ülkemizde kamu kurum ve kuruluşlarının açık veri ekosistemine geçişi için bir finansman kaynağı yaratılmalıdır.

Merkezi idarelerden başlayarak yerel yönetimlere kadar, açık veri uygulamalarını hayata geçirecek kurumlara, önceden belirlenmiş ve yıllara göre güncellenecek şekilde bütçeler tanımlanmalıdır (Yıldırım, 2023). Ülkemizde açık verinin önemi net bir şekilde algılanmamış olmasından dolayı bu türde çalışmalara girişecek kurumlarda önemli engellerden birisi, bu projenin finansmanı ve sürdürülebilir kılınması için oluşturulması gereken ekibin maliyetidir. Karar vericilerin kolay ikna edilebilmesi için açık veri projelerinin finansmanın, merkezi idare tarafından önceden belirlenmiş bütçelerden karşılanması oldukça önemli katkılar verecektir.

5.4. Organizasyonel Çalışmalar

Finansal çalışmalar başlığı altında aktarıldığı üzere, açık veri ekosistemine yönelik yapılacak projelerde, kurumların mevcut organizasyonel yapısında açık veri birimleri kurulmalıdır. Bu açık veri birimi, kurum içerisinde tüm birimler birlikte çalışabilir hale getirilmelidir. Örneğin; açık veri portal altyapısının oluşturulmasında, açık veri birimi ile bilgi işlemden sorumlu birim ya da birimler uyumlu çalışabilmelidir. Açık veri biriminin, veri sorumluluk matrisini çıkarması, kurumdaki tüm birimler ile uyumlu çalışabilmesi için gerekli organizasyonel değişikliklerin yapılması gerekmektedir. Veri sorumluluk matrisinden kasıt; kurumda hangi verinin hangi birim tarafından üretileceği, ilgili verinin üretilmesi, güncel kılınmasıyla ilgili sorumlu olan birimlerin tanımlandığı matristir. Veri sorumluluk matrisine; TUCBS veri sorumluluk matrisi örnek gösterilebilir (Resmî Gazete, 2019).

Açık veri birimi ve Açık Veri Lideri belirlenmesi açık veri ekosisteminin sürdürülebilir kılınması için çok önemlidir. Açık veri lideri ve açık veri birimi, sistemin hayata geçirilmesi, sürdürülebilir kılınması, kurum içi ve paydaşların açık veri konusunda bilgilendirilmesi ve eğitilmesi, açık veri ekosisteminin tüm paydaşlarını bir araya getirecek etkinlikler düzenlenmesinden sorumlu kılınmalıdır.

5.5. Kültürel Çalışmalar

Açık veri yaklaşımı, tek başına teknik bir konu değildir. Günümüz teknolojilerini kullanarak bir açık veri portalının hayata geçirilmesi çok önemli olmakla birlikte, tek başına yeterli değildir. Açık veriden beklenen etkinin ortaya çıkması için kamu yönetiminde, özel sektör iş yapma şekli, üniversitelerde bilimsel çalışmaların yapılma şekli de dahil birçok alanda kültürel değişimin yaşanması gerekmektedir. Özellikle ülkemizde, açık veri felsefesinin hayatın her alanına girebilmesi için bakış açısı değişikliği gerekmektedir.

Kültürel değişim, uzun soluklu bir çalışmalar bütünüyle sağlanabilecek bir durumdur. Açık veri portalının hayata geçmesinden sonrası, ilgili kurumun dış paydaşları yayınlanan bu veriyi kullanması için motive edecek çalışmalar yapılmalıdır (Mutuku & Colaco, 2012; Foulonneau vd., 2014; Yang & Kankanhalli, 2013; Kalampokis, 2011). Bu çalışmalar içerisinde, yayınlanan açık verileri kullanarak çeşitli çalışmaların yapılmasını sağlayacak, küçük ödülleri olduğu yarışmalar (hackathon) düzenlenebilir. Küçük ödüllü yarışmalar ile amatör seviyedeki kullanıcıların açık verilerle iş yapma alışkanlığı geliştirilebilir. Bu yarışmaların dışında, profesyonel düzeyde açık veri çalışması yapan girişimciler ve şirketlerin

ilgisini çekebilmek için belirli hedefleri olan çağrılar yapılarak ürünler geliştirilmesi sağlanabilir. Üniversite öğrencileri, bilim insanları ve akademinin de sürece dahil edilebilmesi için açık veri temalı konferans ve kongre gibi etkinlikler düzenlenebilir.

5.6. Açık Veriye Geçiş Yol Haritası

Politika ve Yasal Çalışmalar;

1. Açık veri fizibilite çalışmalarının gerçekleştirilmesi
2. Açık veri vizyon dokümanı oluşturulması
3. Açık veri strateji dokümanı oluşturulması
4. Açık veri yol haritası dokümanı oluşturulması
5. Açık veri yayınlama yönergesi

Organizasyonel Çalışmalar;

1. Kurumun organizasyonel yapısına yönelik çalışmaların gerçekleştirilmesi
2. Açık veri biriminin kurulması
3. Açık veri lideri atanması
4. Açık veri birimi ve personel atamasının gerçekleştirilmesi

Finansal Çalışmalar;

1. Açık veri portal geliştirilmesine yönelik finansal çalışmaların gerçekleştirilmesi
2. Açık veri portal geliştirim bütçesinin belirlenmesi
3. Açık veri portal donanım altyapısı bütçesinin belirlenmesi
4. Açık veri tanım ve bilgilendirme çalışmalarının bütçenin belirlenmesi
5. Tanıtım ve eğitim bütçesinin belirlenmesi

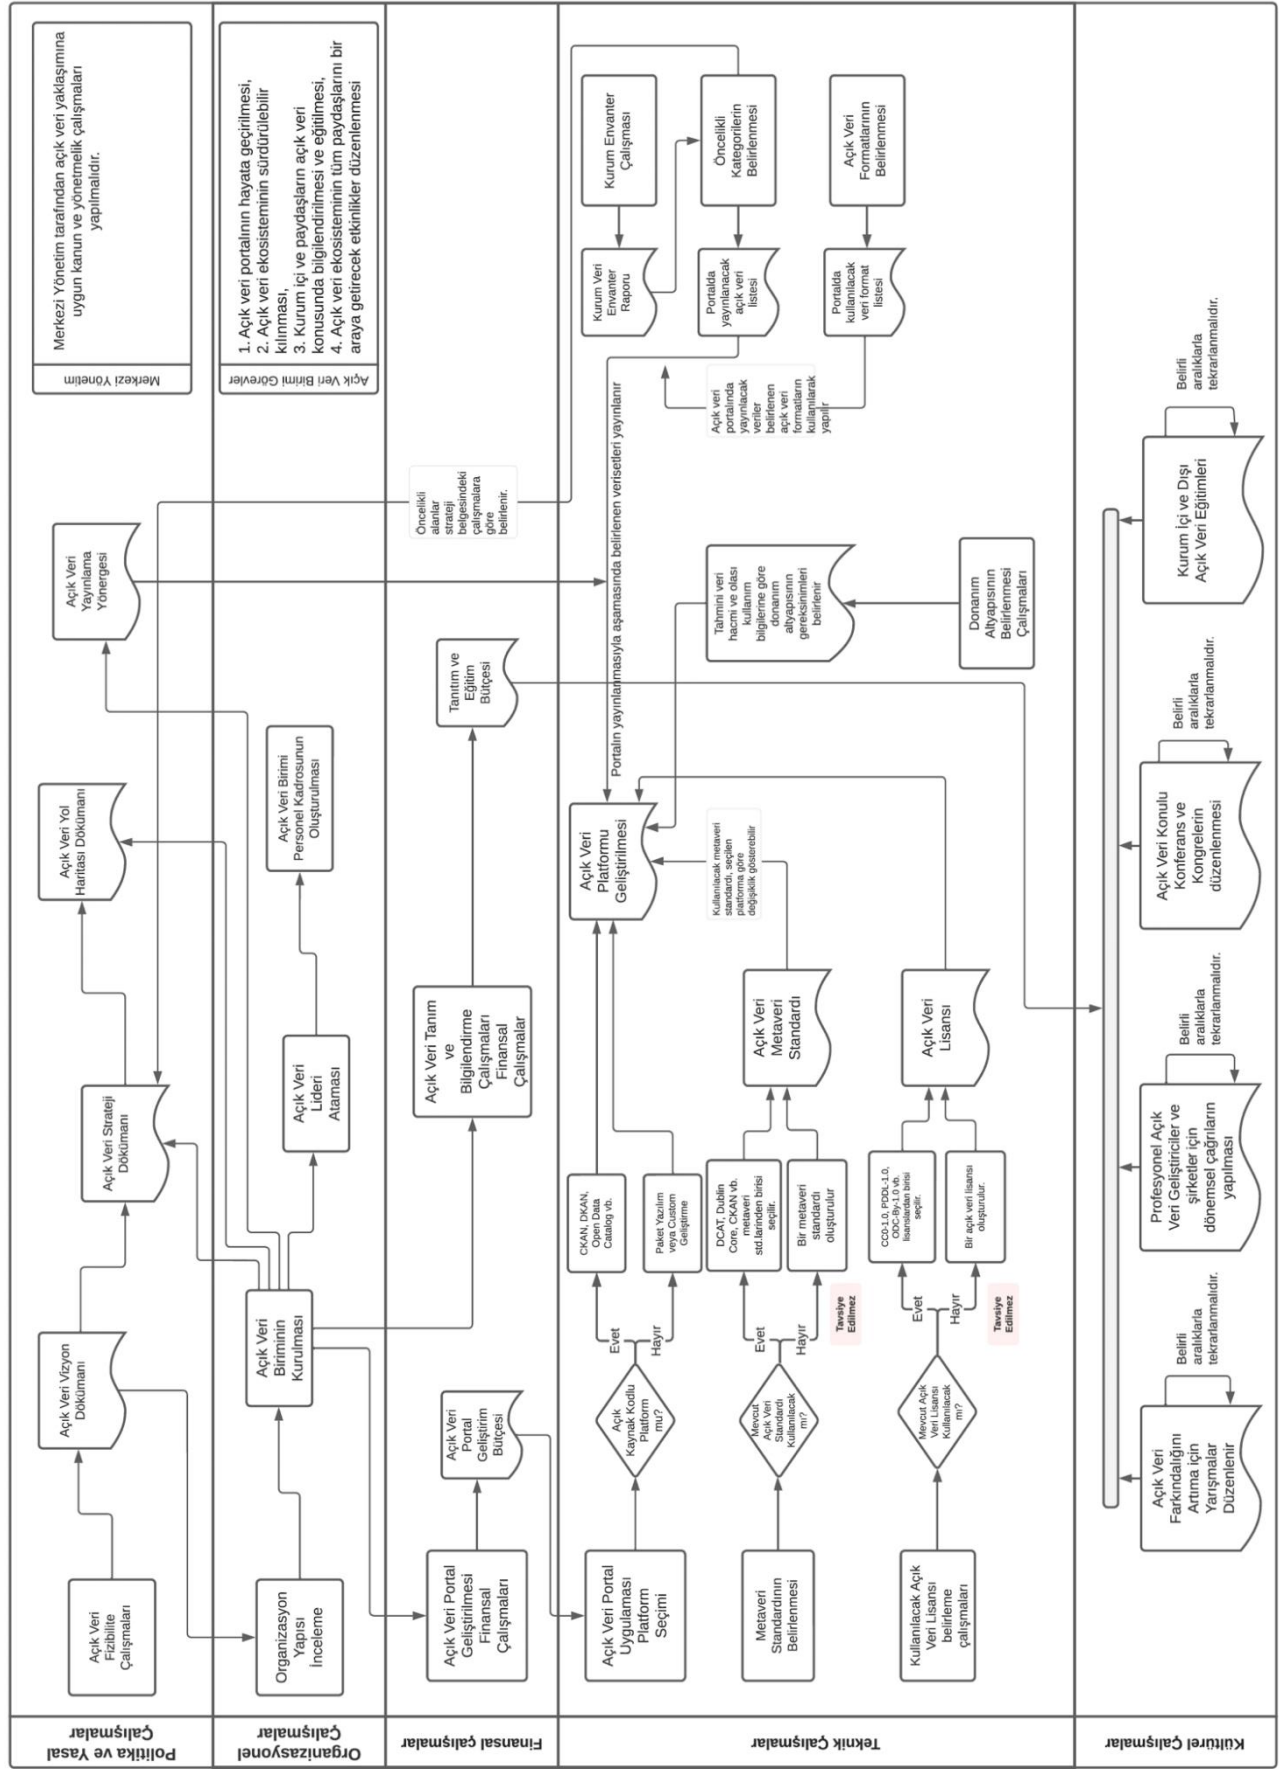
Teknik Çalışmalar;

1. Açık veri portal platformunun seçilmesi; açık kaynak kodlu platform mu yoksa ticari paket yazılım platformu mu kullanılacağına kararının verilmesi
2. Metaveri standardının belirlenmesi; mevcut açık veri metaveri standardı mı kullanılacak yoksa yeni bir metaveri standardı belirleneceğinin kararının verilmesi.
3. Kullanılacak açık veri lisansı belirlenmesi; mevcut açık veri lisanslarından birinin seçilmesi ya da bir açık veri lisansının oluşturulması
4. Açık veri portal uygulamasının geliştirilmesi ve yayınlanması
5. Açık veri metaveri standardının belirlenmesi ve yayınlanması
6. Açık veri lisansının belirlenmesi ve yayınlanması
7. Kurum veri envanter raporunun oluşturulması
8. Öncelikli veri kategorilerinin belirlenmesi
9. Öncelikli veri kategorilerine göre yayınlanacak açık veri listesinin belirlenmesi
10. Kullanılacak açık veri formatlarının belirlenmesi

Kültürel Çalışmalar;

1. Açık veri farkındalığını artıracak yarışmaların belirli aralıklarla düzenlenmesi
2. Profesyonel geliştiriciler ve şirketler için belli aralıklarla dönemsel çağrıya çıkılması
3. Açık veri konulu konferans ve kongrelerin düzenlenmesi ve bu konuda yapılan konferans ve kongrelere katılım sağlanması ve bilinirliğin artırılması çalışmalarının gerçekleştirilmesi
4. Kurum içi ve dışı açık veri eğitimlerinin düzenlenmesi

Bu çalışma kapsamında önerilen açık veriye geçiş yol haritası, açık veriye geçiş yapmak isteyen kamu kurum ve kuruluşları, üniversiteler, vakıf ve dernekler, şirketler için önemli bir katkı sağlayacaktır. Açık veri çalışmalarının bu yol haritası izlenerek gerçekleştirilmesiyle, sürdürülebilir bir açık veri ekosisteminin oluşturulması sağlanacaktır (Şekil 3).



Şekil 3. Açık veriye geçiş yol haritası

6. Ülkemizde Açık Verinin Yasal Durumu

2001 yılında Anayasa’da yapılan değişiklikle Dilekçe, bilgi edinme ve kamu denetçisine başvurma hakkı başlığı altında Madde 74’te Vatandaşlar ve karşılıklılık esası gözetilmek kaydıyla Türkiye’de ikamet eden yabancılar kendileriyle veya kamu ile ilgili dilek ve şikayetleri hakkında, yetkili makamlara ve Türkiye Büyük Millet Meclisine yazı ile başvurma hakkına sahiptir. “Kendileriyle ilgili başvuruların sonucu gecikmeksizin, dilekçe sahiplerine yazılı olarak bildirilir” ifadesiyle bilgi edinme hakkına yönelik tanım yapılmıştır. 2004 yılında çıkarılan 4982 sayılı Bilgi Edinme Hakkı kanunu çıkarılmıştır. 2004/12 sayılı Başbakanlık tarafından, Dilekçe ve Bilgi Edinme Hakkının kullanılması konusunda genelge yayınlanmıştır. Bu kanun ve genelgeler kapsamında, vatandaş kamu kurum ve kuruluşlarından bilgi edinme hakkına yönelik düzenleme ile fiziksel ve dijital veri talep edebilir. Bu talebin, 15 gün içerisinde ilgili kamu kurum ve kuruluşlar tarafından karşılanması gerekmektedir. Ayrıca açık veri çalışmalarına yönelik çeşitli hedefler, ülkemizde çeşitli eylem planlarına girdiği görülmektedir (T.C. Kalkınma Bakanlığı, 2015; T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı, 2016; T.C. Çevre ve Şehircilik Bakanlığı, 2019). Vatandaşın bilgi edinme hakkına yönelik yapılan çeşitli düzenlemelerin olması, kamu kurum ve kuruluşlarında açık verinin yasal dayanağı olduğu anlamına gelmemektedir. Ülkemizde açık verinin herhangi bir yasal dayanağı bulunmamaktadır. Bu durum, çeşitli yerel yönetim seviyelerinde hayata geçirilmiş olan açık veri portallarında yayınlanan verilerin hem sayısal olarak hem de etki (impact) bakımından zayıf kalmasına sebebiyet vermektedir.

Etkisi yüksek olan verilerin, kurum içi kaynaklar kullanılarak üretilmesinden ziyade, çoğunlukla çeşitli ihale yöntemleri kullanılarak üretililecek verilerdir (European Union, 2022b). Avrupa birliği açık veri portalında, etkisi yüksek konumsal verilere İdari Sınırlar, Coğrafi Yer İşaretleri, Adres, Bina, Kadastro parseli gibi veri setleri örnek verilmiştir. Özellikle, bina, kadastro parseli gibi verilerin kurumların ihale yoluyla ürettiği açıktır. Mevcut kanuni altyapı, ihale yoluyla üretilmiş bir verinin herhangi bir ücret almadan ücretsiz bir şekilde yayınlanmasının kamu zararı oluşturduğuna dair bir bakış açısı doğurmaktadır. Dolayısıyla açık veri çalışmalarında etkisi büyük olan verilerin yayınlanmasında halen sorunlar olduğu görülmektedir. Kamu kurum ve kuruluşların, Sayıştay denetimlerinde bu konuda sorun yaşamaması için açık devlet politikalarını açık ve net bir şekilde destekleyecek kanuni altyapı hazırlanmalıdır.

İzmir Büyükşehir Belediyesi tarafından yayınlanan Açık Veri Strateji (International Finance Corporation, 2020) dokümanında, belediyenin sahip olduğu veriyi vatandaşın kullanımına açılmasının üzerinde herhangi bir yasal engel olmadığı ifade edilmiştir. Mevcut durumda ülkemizde açık veri yaklaşımlarını engelleyecek çeşitli yasal düzenlemeler olduğu görülmektedir. Açık veri girişimleri incelendiğinde yayınlanan ve etkisi yüksek verilerinin önemli bir kısmı konuma dayalı ya da coğrafi bilgi sistemlerine yönelik veriler olduğu görülmektedir. Özellikle girişimcilerin, iş modelleri yaratabileceği veriler içerisinde en önemli alanın CBS verileridir.

Tablo 7. Açık veri portallarındaki yayınlanan CBS verisi istatistikleri (Quarati vd., 2021)

Country	Portal	Veriseti	Coğrafi Veriseti	Oran	Platform
U.S.	data.gov	261,514	157,064	%60	CKAN
U.K.	data.gov.uk	55,664	17,940	%32	CKAN
Almanya	govdata.de	130,976	17,092	%13	CKAN
HDX	data.humdata.org	17,325	4,080	%24	CKAN
EUODP	data.europa.edu	14,058	1,847	%13	CKAN
NASA	data.nasa.gov	9,664	1,087	%11	Socrata

Tablo 7’de CBS verisinin seçilen örnek açık veri portallarında yayınlanan tüm açık verilerdeki oranı görülmektedir. Örneğin; Amerika Birleşik Devletleri portalında, konumsal verilerin diğer verileri oranı %60 olduğu görülmektedir. CBS verisinin, açık veri çalışmalarında yüksek katma değerli veriler sunulması açısından ne kadar önem arz ettiği, Almanya açık veri portalına bakıldığında anlaşılmaktadır. Almanya açık veri portalında, yalnızca yüksek kaliteli veriler etiketi ile yayınlanan 5,918 verinin, 4,362’si coğrafi veri barındırmaktadır. CBS verisinin diğer verilere oranı %73 olduğu görülmektedir. Açık veri çalışmasında CBS verisinin önemi ortaya çıkmaktadır.

Ülkemizde, 2020 yılında yayınlanan 7221 sayılı Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun (T.C. Resmi Gazete, 2020a) ve bu kanunu takiben, 2021 yılında 31391 sayılı Coğrafi Veri Lisans Yönetmeliği (T.C. Resmi Gazete, 2021a) ve Coğrafi Veri İzinleri Yönetmeliği (T.C. Resmi Gazete, 2021b), coğrafi bilgi sistemleri kapsamında, veri üretim, dağıtım, satış ve paylaşım konularında çeşitli kısıtlamalar getirmektedir. 7221 sayılı Coğrafi Bilgi Sistemleri İle Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun Madde 1 (2) nolu bendinde, “Gerçek kişilerin ve özel hukuk tüzel kişilerinin Türkiye’ye ait Ulusal Coğrafi Veri Sorumluluk Matrisi kapsamındaki coğrafi verileri toplaması, üretmesi, paylaşması veya satması; fikrî, sınai ve ticari haklara ilişkin mevzuat hükümleri ile Kişisel Verilerin Korunması Kanunu ve özel kanunlardaki hükümler saklı kalmak kaydıyla ve ticari faaliyetleri gerçekleştirmek için gerekli belgelere sahip olması şartı ile Çevre, Şehircilik ve İklim Değişikliği Bakanlığının iznine tabidir. İzne tabi olacaklar ile izin

süresi ve verilere ilişkin usul, esas ve içerikler Çevre, Şehircilik ve İklim Değişikliği Bakanlığınca belirlenir. İzin bedeli 1/1000'lik pafta başına, yabancı gerçek kişiler ve özel hukuk tüzel kişileri için 50 TL, yerli gerçek kişiler ve özel hukuk tüzel kişileri için 25 TL'dir. Bu tutarlar takvim yılı başından geçerli olmak üzere her yıl bir önceki yıla ilişkin olarak 4/1/1961 tarihli ve 213 sayılı Vergi Usul Kanununun mükerrer 298 inci maddesi hükümleri uyarınca tespit ve ilan edilen yeniden değerlendirme oranında artırılarak uygulanır." hükmü bulunmaktadır. İlgili kanunun Madde 1 (2) nolu bendinde bahsi geçen Ulusal Coğrafi Veri Sorumluluk Matrisi 2020 yılında 31171 nolu Türkiye Coğrafi Bilgi Sistem Kurulu Kararı ile yayınlanmıştır (T.C. Resmi Gazete, 2020b).

Bu sorumluluk matrisi incelendiğinde, 2019 yılında yayınlanan 49 sayılı Coğrafi Bilgi Sistemleri hakkında Cumhurbaşkanlığı Kararnamesinde (1) sayılı liste olan Coğrafi Veri Temaları baz alınarak, çeşitli kurumlara çeşitli verilerin üretim sorumluluğu verilmiştir (T.C. Resmi Gazete, 2019). İlgili tema listesi incelendiğinde, neredeyse bu kapsamında dışında herhangi bir coğrafi veri üretim imkânının olmadığı görülmektedir. Ülkemizde, an itibariyle Çevre ve Şehircilik Bakanlığı Coğrafi Bilgi Sistemleri Genel Müdürlüğü izni olmadan ticarete konu olsun ya da olmasın herhangi bir alanda yasal olarak CBS verisi üretimi, satışı ve paylaşımı mümkün değildir. Bu durum açık veri yaklaşımının yeniden kullanım ve yeniden dağıtım ilkesini açıkça ihlal etmektedir.

Ayrıca vurgulanması gereken diğer bir konu ise ilgili kanun ve yönetmeliklerle tanımlanmış izin ücrete tabidir. Coğrafi veri kullanımı için izin prosedürünün yürütülmesi, açık veri yaklaşımının ilkelerinden bir diğeri olan; evrensel erişim ilkesinin hayata geçirilmesini de engellemektedir. Evrensel erişim ilkesi, verinin herhangi bir grubun veya ticari firmaların kullanımına kısıtlanamayacak olmasıdır. Coğrafi veri kullanımının izne tabi olması, ayrıcalıklı bir grup oluşmasına sebebiyet vermektedir. Ayrıca, her ne kadar açık veri portallarından veri ücretsiz dağıtılsa da bu verinin kullanımı, dağıtımı ya da ticari bir faaliyete konu edilmesinde ödenmesi gereken bir yıllık bedelin olması, açık verinin ücretsiz olması ilkesine karşı bir durumdur. 7221 sayılı kanunun Madde 1 (1) bendinde "*Ulusal Coğrafi Veri Paylaşım Matrisine göre kamu kurum ve kuruluşları arasında paylaşımı, erişimi ve kullanımı bedelsizdir*" ifadesi ülkemizde çok yavaş ilerleyen açık veri çalışmalarına engel oluşturabilecek bir kanuni maddedir. Halihazırda açık veri ekosisteminin oluşturulması konusunda zaten oldukça isteksiz olan kamu kurum ve kuruluşları için bir dayanak noktası oluşturmaktadır. İlgili kanunun bu maddesi, kurumlar arasındaki veri paylaşımı için doğru olarak gözükmekle beraber veri paylaşımını belli bir gruba yönelik yapılması noktasında aslında bir kısıtlamadır. İlgili madde tersten okunduğunda, kamu kurumları dışındaki taraflara verilerin paylaşımının, erişiminin ve kullanımının ücrete tabi olması gerekliliğini vurgulamaktadır. Daha net bir ifade ile bu maddede kamu kurumlarına sahip oldukları verileri kamu kurum ve kuruluşları dışındaki taraflara ücretsiz paylaşamayacağını söylemektedir. Bu durum açık veri yaklaşımının verilerinin ücretsiz olması ilkesine ters düşmektedir.

Açık verilerin başka verilerle çeşitli çalışmalar gerçekleştirerek yeni veriler haline getirilmesi, açık veri yaklaşımının önemli hedeflerinden birisidir. Ülkemizdeki coğrafi veriler için çıkarılan kanun ve yönetmelikler CBS verisini açık veri olmasını engellemesinin yanı sıra açık veri olarak yayınlanan bir verinin coğrafi bir veriyle birleştirilerek yeni bir verinin üretilebilmesini engellemektedir.

7. Sonuç ve Öneriler

Bu çalışma kapsamında, açık veri konusunda yapılan detaylı çalışma ile açık verinin önemi vurgulanmıştır. Ülkemizdeki açık veri çalışmalarına yönelik yapılan incelemeler sonucunda, açık veri yaklaşımının net bir şekilde anlaşılmadığı görülmektedir. Bu çalışma kapsamında bir verinin açık veri olarak kabul edilmesi için sağlaması gereken koşullar net bir şekilde ifade edilmiştir. Katma değeri yüksek verilerin, çok kısıtlı düzeyde açık veri olarak yayınlandığı görülmektedir. Açık veri ekosisteminin sürdürülebilirliği için katma değeri yüksek verilerin açık veri olarak yayınlanması, açık veri kültürünün ülkemizde hızla genişlemesine yardımcı olacaktır. Özellikle kamu kurumlarının sahip oldukları verileri açık veri olarak yayınlaması için *kamu kaynaklarıyla üretilen verilerin kamuya mâl edilmesi* ilkesi ortaya konulmuştur. Bu ilke doğrultusunda kişisel veriler ve ülke güvenliğini tehlikeye atacak verilerin dışındaki tüm veriler açık veri lisans koşulları altında yayınlanmalıdır.

Açık veriye geçiş yapacak tüm kurum ve kuruluşların, açık veriye geçiş sürecini sağlıklı bir şekilde yönetebilmesi için bu çalışma kapsamında açık veri yol haritası oluşturulmuştur. Açık veriye geçiş yol haritasıyla, sıfırdan bu süreçlere başlayacak kurumlara ilişkin detaylı bir plan sunulmaktadır. Bu yol haritası, açık veriye geçiş yapacak kurum ve kuruluşlar tarafından kullanılmasıyla açık veri ekosisteminin daha sağlıklı bir şekilde hayata geçirilmesini sağlanacaktır.

Ülkemizdeki kanuni altyapı göz önüne alındığında, bir açık veri ekosisteminin hayata geçmesi ve sürdürülebilir bir şekilde yaşama engel olacak kanuni hükümlerin olduğu görülmektedir. Bu durum, açık veri çalışmalarının ülkemizde yavaş bir şekilde ilerlemesi veya hiç başlayamamasına sebep olacaktır. Özellikle, konumsal verinin üretimi, paylaşılması konusunda yayınlanan kanun ve yönetmeliklerdeki engelleyici hükümlerin acil bir şekilde yürürlükten kaldırılması gerekmektedir. Hızlı bir şekilde açık veri yaklaşımının önünü açacak kanuni düzenlemelerin yapılması ve bunu takiben destekleyici kanun ve yönetmeliklerin oluşturulması gerekmektedir. Yürürlükte olan kanun ve yönetmeliklerin özellikle coğrafi verinin CBS Genel Müdürlüğü'nün izni olmaksızın yeniden kullanım ve dağıtımını engelleyici hükümler içermesi nedeniyle *ülkemizde yasal açıdan açık veri çalışması yapılması mümkün değildir*.

Kaynaklar

- Akıncı, H. (2006). *Konumsal veri altyapılarının Web servisleri ile gerçekleştirilmesi: Mevcut durum analizi ve gelecek yönelimlerinin belirlenmesi* [Doktora tezi, Karadeniz Teknik Üniversitesi]. Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Apanasevic, T. (2021, June 21–23). *Socio-economic effects and the value of open data: A case from Sweden* [Conference presentation]. 23rd Biennial Conference of the International Telecommunications Society (ITS), Gothenburg, Sweden.
- Berners-Lee, T. (2012, 9 Kasım). *Raw data, now*. Wired UK. <https://www.wired.co.uk/article/raw-data>
- Chignard, S. (2013, March 29). *A brief history of open data*. <https://www.paristechreview.com/2013/03/29/brief-history-open-data/>
- Corrales-Garay, D., Ortiz de Urbina Criado, M., & Mora-Valentín, E.-M. (2020). A research agenda on open data impact process for open innovation. *IEEE Access*, 8, 34696–34705. <https://doi.org/10.1109/ACCESS.2020.2974378>
- Cömert, Ç. (1998). Ulusal konumsal veri altyapısı üzerine. *TMMOB HKMO Bülteni*, Temmuz 1998, 84–86.
- Cömert, Ç. (2004, July 12–23). *Web services and national spatial data infrastructures* [Conference presentation]. XXth ISPRS Congress, Istanbul, Türkiye.
- Cömert, Ç., & Banger, G. (1996, 26–28 Eylül). *Ulusal konumsal veri altyapısı* [Bildiri sunumu]. Coğrafi Bilgi Sistemleri Sempozyumu, Istanbul, Türkiye.
- Creative Commons. (2013a). *CC0. "No Rights Reserved"*. <https://creativecommons.org/share-your-work/public-domain/cc0/>
- Creative Commons. (2013b). *CC BY 4.0 Attribution 4.0 International*. <https://creativecommons.org/licenses/by/4.0/>
- Creative Commons. (2013c). *Attribution-Share Alike 4.0 International (CC BY-SA 4.0)*. <https://creativecommons.org/licenses/by-sa/4.0/>
- Data.gov. (2014). *DCAT-US Schema v1.1 (Project Open Data Metadata Schema)*. <https://resources.data.gov/resources/dcat-us/>
- Dawes, S., Vidasova, L., & Parkhimovich, O. (2016). Planning and designing open government data programs: An ecosystem approach. *Government Information Quarterly*, 33(1), 15–27. <https://doi.org/10.1016/j.giq.2016.01.003>
- Eckartz, S., van den Broek, T., & Ooms, M. (2016). Open data innovation capabilities: Towards a framework of how to innovate with open data. In H. J. Scholl, O. Glassey, M. Janssen, B. Klievink, I. Lindgren, P. Parycek, E. Tambouris, M. A. Wimmer, T. Janowski, & D. Sá Soares (Eds.), *Electronic Government* (pp.47–60). Springer, Cham.
- European Commission. (2013). *DCAT Application Profile for data portals in Europe*. <https://interoperable-europe.ec.europa.eu/collection/semic-support-centre/solution/dcat-application-profile-data-portals-europe>
- European Union. (2021). *Open Data in Europe 2021*. <https://data.europa.eu/en/publications/open-data-maturity/2021>
- European Union. (2022a). *Open Data in Europe 2022*. <https://data.europa.eu/en/publications/open-data-maturity/2022>
- European Union. (2022b, November 22). High-value datasets – an overview through visualisation. <https://data.europa.eu/en/publications/datastories/high-value-datasets-overview-through-visualisation>
- Foulonneau, M., Martin, S., & Turki, S. (2014). How open data are turned into services? In M. Snene, & M. Leonard (Eds.), *Exploring Services Science, Lecture Notes in Business Information Processing* (Vol. 169, pp. 31–39). Springer International Publishing.
- Goodey, G., Hahnel, M., Zhou, Y., Jiang, L., Chandramouliswaran, I., Hafez, A., Paine, T., Gregurick, S., Simango, S., Peña, J., Murray, H., Cannon, M., Grant, R., McKellar, K., & Day, L. (2022). *The State of Open Data 2022: The longest-running longitudinal survey and analysis on open data*. Digital Science Report. <https://doi.org/10.6084/m9.figshare.21276984.v5>
- Günaydaş, M., & Güney, C. (2019). Mekansal veri altyapılarında paradigma değişimi: açık veri ekosisteminde mekansal bağlantılı veri altyapıları. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 19, 369–389.
- Hansson, K., Ekenberg, L., & Belkacem, K. (2014). Open government and democracy: a research review. *Social Science Computer Review*, 33(5), 540–555. <https://doi.org/10.1177/0894439314560847>
- Harrison, T., Pardo, T., & Cook, M. (2012). Creating open government ecosystems: A research and development agenda. *Future Internet*, 4(4), 900–928. <https://doi.org/10.3390/fi4040900>
- Hollyer, J. R., Rosendorff, B. P., & Vreeland, J. R. (2011). Democracy and transparency. *The Journal of Politics*, 73(4), 1191–1205. <https://doi.org/10.1017/s0022381611000880>
- International Finance Corporation. (2020). *İzmir Büyükşehir Belediyesi Açık Veri Stratejisi*. https://acikveri.bizizmir.com/tr/Document/Izmir_Acik_Veri_Stratejisi.pdf
- Jetzek, T. (2016). Managing complexity across multiple dimensions of liquid open data: The case of the Danish Basic Data Program. *Government Information Quarterly*, 33(1), 89–104. <https://doi.org/10.1016/j.giq.2015.11.003>

- Jetzek, T., Avital, M., & Bjorn-Andersen, N. (2014). Data-driven innovation through open government data. *Journal of Theoretical and Applied Electronic Commerce Research*, 9(2), 100–120.
- Judie, A., Fabrizio, O., Simon, S., & Sören, A. (2015). A systematic review of open government data initiatives. *Government Information Quarterly*, 32(4), 399–418. <https://doi.org/10.1016/j.giq.2015.07.006>
- Kalampokis, E., Hausenblas, M., & Tarabanis, K. A. (2011). Combining social and government open data for participatory decision-making. In E. Tambouris, A. Macintosh, & H. de Bruijn (Eds.), *Electronic Participation* (pp. 36–47). Springer.
- Kawashita, I., Baptista, A. A., & Soares, D. (2020). *An assessment of open government data benchmark instruments*. <https://ceur-ws.org/Vol-2797/paper2.pdf>
- Krishnamurthy, R., & Awazu, Y. (2016). Liberating data for public value: The case of Data.Gov. *International Journal of Information Management*, 36(4), 668–672. <https://doi.org/10.1016/j.ijinfomgt.2016.03.002>
- Lokers, R., Berdou, E., Miguel Ayala, L., & Mey, L. (2019). *Guidelines for analysing pathways to impact: Evaluation of open data for development*. F1000Research. <https://doi.org/10.7490/f1000research.1117778.1>
- Manyika, J., Chui, M., Farrell, D., Kuiken, S. V., Groves, P., & Doshi, E. A. (2013). *Open data: Unlocking innovation and performance with liquid information*. McKinsey Digital.
- Meijer, A. J., Curtin, D., & Hillebrandt, M. (2012). Open government: Connecting vision and voice. *International Review of Administrative Sciences*, 78(1), 10–29. <https://doi.org/10.1177/0020852311429533>
- Mutuku, L. N., & Colaco, J. (2012, October 22-25). *Increasing Kenyan open data consumption: A design thinking approach* [Conference presentation]. 6th International Conference on Theory and Practice of Electronic Governance, New York, USA.
- National Research Council. (1995). *Finding the forest in the trees: The challenge of combining diverse environmental data*. <https://ntrs.nasa.gov/api/citations/19950019942/downloads/19950019942.pdf>
- Nayek, J. K. (2018). Evaluation of open data government sites: A comparative study. *Library Philosophy & Practice e-journal*, 1781, 1–23.
- Obama, B. (2009). *Memorandum on transparency and open government*. The White House. <https://www.whitehouse.gov>
- Ooijen, C., Osimo, D., & Regeczi, D. (2023). *Rethinking the impact of open data: A first step towards a European impact assessment for open data*. Publications Office of the European Union. <https://data.europa.eu/doi/10.2830/911822>
- Open Data Barometer. (2025, Ocak 7). *Açık veri etki analizi*. <https://opendatabarometer.org/2ndEdition/analysis/impact.html>
- Open Data Commons. (2008). *Public Domain Dedication & License 1.0*. <https://opendatacommons.org/licenses/pddl/1-0/>
- Open Government Working Group. (2007, 22 Ekim). *Open Government Working Group Meeting in Sebastopol, CA*. https://public.resource.org/open_government_meeting.html
- Open Knowledge Foundation. (2009a). *Open Data Commons Attribution License (ODC-By) v1.0*. <https://opendatacommons.org/licenses/by/1-0/>
- Open Knowledge Foundation. (2009b). *Open Data Commons Open Database License (ODbL) v1.0*. <https://opendatacommons.org/licenses/odbl/1-0/>
- Open Knowledge Foundation. (2012). *Open Data Handbook: What is open data?* <https://opendatahandbook.org/guide/en/what-is-open-data/>
- Quarati, A., De Monica, S., & Rosim, S. (2021). Geospatial open data usage and metadata quality. *International Journal of Geo-Information*, 10(1), 1–17. <https://doi.org/10.3390/ijgi10010030>
- Shaharudin, A. A. A. (2020). *Open government data: Principles, benefits and evaluations*. Khazanah Research Institute.
- Susha, I., Zuiderwijk, A., Janssen, M., & Grönlund, A. (2015). Benchmarks for evaluating the progress of open data adoption: Usage, limitations, and lessons learned. *Social Science Computer Review*, 33(5), 613–630. <https://doi.org/10.1177/0894439314560852>
- T.C. Çevre ve Şehircilik Bakanlığı. (2019). *2020-2023 Ulusal Akıllı Şehirler Stratejisi ve Eylem Planı*. <https://www.akillisehirler.gov.tr/wp-content/uploads/EylemPlanı.pdf>
- T.C. Kalkınma Bakanlığı. (2015). *2015-2018 Bilgi Toplumu Stratejisi ve Eylem Planı*. <https://abdigm.meb.gov.tr/projeler/ois/004.pdf>
- T.C. Resmi Gazete. (2019). *Coğrafi Bilgi Sistemleri Hakkında Cumhurbaşkanlığı Kararnamesi* (Resmi Gazete Tarih: 07.11.2019, Sayı: 30941). <https://webdosya.csb.gov.tr/db/cbs/icerikler/19.5.49-20240328153642.pdf>
- T.C. Resmi Gazete. (2020a). *Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun* (Resmi Gazete Tarih: 20.02.2020, Sayı: 31045). <https://www.resmigazete.gov.tr/eskiler/2020/02/20200220-1.htm>
- T.C. Resmi Gazete. (2020b). *Türkiye Coğrafi Bilgi Sistemi Kurul Kararı* (Resmi Gazete Tarih: 30.06.2020, Sayı: 31171) <https://www.resmigazete.gov.tr/eskiler/2020/06/20200630-14.pdf>
- T.C. Resmi Gazete. (2021a). *Coğrafi Veri Lisans Yönetmeliği* (Resmi Gazete Tarih: 10.02.2021, Sayı: 31391). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=38319&MevzuatTur=7&MevzuatTertip=5>

- T.C. Resmi Gazete. (2021b). *Coğrafi Veri İzinleri Yönetmeliği* (Resmi Gazete Tarih: 10.02.2021, Sayı: 31391). <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=38318&MevzuatTur=7&MevzuatTertip=5>
- T.C. Ulaştırma Denizcilik ve Haberleşme Bakanlığı. (2016). *2016-2019 Ulusal e-Devlet Stratejisi ve Eylem Planı*. <http://www.sp.gov.tr/upload/xSPTemelBelge/files/Swkoy+2016-2019-Ulusal-e-Devlet-Stratejisi-ve-Eylem-Plani.pdf>
- The Global Economy.com. (2023). *Turkey: Percent of world GDP*. https://www.theglobaleconomy.com/Turkey/gdp_share/
- The National Archives. (2023, 7 Ocak). *Open government licence for public sector information*. <https://www.nationalarchives.gov.uk/doc/open-government-licence/version/3/>
- The White House. (2013, May 9). *Executive Order: Making open and machine-readable the new default for government information*. <https://obamawhitehouse.archives.gov/the-press-office/2013/05/09/executive-order-making-open-and-machine-readable-new-default-government>
- Umbrich, J., Neumaier, S., & Polleres, A. (2015, August 24–26). *Quality assessment and evolution of open data portals* [Conference presentation]. 3rd International Conference on Future Internet of Things and Cloud, Rome, Italy.
- Verhulst, S., & Young, A. (2017). *Open data in developing economies: Toward building an evidence base on what works and how*. <https://papers.ssrn.com/abstract=3141435>
- Wenige, L., Stadler, C., Martin, M., Figura, R., Sauter, R., & Frank, C. (2021). *Open data and the status quo: A fine-grained evaluation framework for open data quality and an analysis of open data portals in Germany*. ArXiv. <https://arxiv.org/pdf/2106.09590>
- Wocken, M. (2022). *The potential of open data for startups and companies*. Founders Foundation. <https://foundersfoundation.de/en/content-library/the-potential-of-open-data-for-startups-and-companies/>
- Yang, Z., & Kankanhalli, A. (2013). Innovation in government services: The case of open data. In Y. K. Dwivedi, H. Z. Henriksen, D. Wastell, & R. De (Eds.), *Grand Successes and Failures in IT: Public and Private Sectors* (pp. 644–651). Springer.
- Yankova, M. (2016). *Open data innovation? Open your data and see it happen*. <https://www.ontotext.com/blog/open-data-innovation/>
- Yıldırım, M. E. (2023). *Konumsal veri sunumunda modern yaklaşım önerilerinin geliştirilmesi* [Doktora tezi, Karadeniz Teknik Üniversitesi]. Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Yıldırım, M. E. (2023, 22–23 Aralık). *Sürdürülebilir kent yönetiminde açık verinin rolü* [Bildiri sunumu]. 3. İzmir Kent Sempozyumu, İzmir, Türkiye.
- Zuiderwijk, A., Janssen, M., Choenni, S., Meijer, R., & Sheikh_Alibaks, R. (2012). Socio-technical impediments of open data. *Electronic Journal of e-Government*, 10, 156–172.

Copernicus Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) Verileri Kullanılarak Geçirimsizlik Derecelerinin Haritalanması ve Gelecek Tahmini: Amasya Kenti Örneği

Mapping of Imperviousness Degrees and Future Prediction Using Copernicus High Resolution Layer Imperviousness Density (HRL IMD) Data: The Case of Amasya City

Sultan Sevinç Kurt Konakoğlu¹, Tuğba Üstün Topal², Berkant Konakoğlu^{3*}

¹Amasya Üniversitesi, Mimarlık Fakültesi, Kentsel Tasarım ve Peyzaj Mimarlığı Bölümü, 05100, Amasya/Türkiye.

²Tekirdağ Namık Kemal Üniversitesi, Güzel Sanatlar, Tasarım ve Mimarlık Fakültesi, Peyzaj Mimarlığı Bölümü, 59030, Tekirdağ/Türkiye.

³Amasya Üniversitesi, Teknik Bilimler MYO, Mimarlık ve Şehir Planlama Bölümü, Harita ve Kadastro Programı, 05100, Amasya/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Berkant Konakoğlu
berkantkonakoglu@amasya.edu.tr

doi: 10.48123/rsgis.1602126

Yayın süreci

Geliş tarihi: 15.12.2024

Kabul tarihi: 06.03.2025

Basım tarihi: 26.03.2025

Özet

Sürdürülebilir kentsel planlama için kentlerdeki yapılaşmış alanların ve ortaya çıkardığı kentsel koşulların kapsamlı bir şekilde ele alınması oldukça önemlidir. Bu çalışmada, Copernicus Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) verileri kullanılarak (2006, 2009, 2012, 2015 ve 2018 yılları) Amasya kenti ölçeğinde kentsel geçirimsizlik dereceleri sınıflandırılarak haritalanmış ve yıllara göre kentsel arazi değişim oranları hesaplanmıştır. Çalışmada, belirlenen değişimlerin aynı şekilde devam etmesi durumunda gelecekteki (2030 yılı) geçirimsizlik derecelerinin ne olabileceğini belirlemek amacıyla doğrusal ve polinom regresyon modelleri kullanılarak matematiksel hesaplamalar yapılmıştır. Çalışma sonucuna göre, Amasya iline bağlı tüm ilçelerde ilgili yıllar boyunca kentleşmenin artış eğilimi gösterdiği ve bu durumun geçirimsiz yüzey alanlarındaki artışla paralellik gösterdiği tespit edilmiş olup, gelecekte de söz konusu geçirimsiz yüzeylerin önemli ölçüde artmaya devam edeceği öngörülmektedir. Bu bağlamda, Amasya kentinin bir pilot bölge olarak değerlendirildiği bu çalışma ile önümüzdeki yıllarda geçirimsiz yüzey alan değişimlerinin düzenli olarak gözlemlenmesi ve kontrollü bir kentleşme politikasının geliştirilerek uygulanmasının, doğal alanların korunması ve biyolojik tahribatın önlenmesinde etkili olabileceği düşünülmektedir.

Anahtar kelimeler: Copernicus, Geçirimsizlik yoğunluğu, Amasya, Kentleşme

Abstract

It is very important to comprehensively address built-up areas in cities and the resulting urban conditions for sustainable urban planning. In this study, using Copernicus High Resolution Layer Imperviousness Density (HRL IMD) data (2006, 2009, 2012, 2015, and 2018), urban imperviousness degrees were classified and mapped at the scale of Amasya city and urban land change rates were calculated over the years. In the study, mathematical calculations were made using linear and polynomial regression models to determine what the future (2030) imperviousness degrees would be if the determined changes continue in the same way. According to the results of the study, it has been determined that urbanization has shown an increasing trend in all districts of Amasya province during the relevant years and this situation has been parallel to the increase in impervious surface areas, and it is predicted that these impervious surfaces will continue to increase significantly in the future. In this context, with this study, in which the city of Amasya is evaluated as a pilot region, it is concluded that regular observation of impervious surface area changes in the coming years and the development and implementation of a controlled urbanization policy will help to protect natural areas and prevent biological damage.

Keywords: Copernicus, Imperviousness density, Amasya, Urbanization

1. Giriş

Kentler; binalar, yollar, kaldırımlar, ormanlık alanlar, sanayi alanları, parklar, yeşil alanlar, eğitim alanları, sağlık alanlarından oluşan en üst düzeyde iş bölümünün olduğu mekânlardır (Simmel, 1996). Sanayi Devrimi ile birlikte kentlerde görülen ani ve kontrolsüz nüfus artışı kentlerin plansız ve altyapıdan yoksun gelişmesine, yapılaşmanın artmasına, kentleşme sürecinin hızlanmasına, ormanlık alanların tahrip edilerek yeşil alanların azalmasına, çevre kirliliğinin artmasına, arazi kullanımı/arazi örtüsünde (AKAÖ) değişimlere, yüzey akışının değişmesine, buharlaşma yüzeylerinin yok olmasına, geçirimsiz sert zemin yüzeylerin artmasına ve atmosferin olması gerektiğinden fazla ısınmasına neden olmaktadır (Davis, 1955; Ataöv & Osmay, 2007; Berry, 2008; Mohan vd., 2011; Ersoy Tonyaloğlu, 2019; Liang & Gong, 2020; Kim vd., 2022). Bu süreçlerin bir sonucu olarak küresel sıcaklıkta sürekli bir artış meydana gelmekte ve dolayısıyla iklim değişikliği görülmektedir (Dale vd., 2000; Bayraç, 2010; Dong vd., 2014; Kaplan vd., 2018; T.C. İstanbul Büyükşehir Belediyesi, 2023). İklim değişikliği; ani yağışlar, kuraklık, çölleşme, orman yangınları, fırtına, sel ve taşkınlar gibi doğal afetlere neden olabilmektedir (Akay, 2019). Nitekim kentleşme, günümüzde küresel ısınma ve iklim değişikliğine neden olan en önemli olgulardan biri olarak görülmektedir (Sarrat vd., 2006; World Health Organization, 2018).

Kentleşme, hem kentlerin hem de kentte yaşayan insanların fiziksel, sosyal ve ekonomik yapılarında önemli değişimlere neden olan bir süreçtir (Zhou vd., 2016). Kentleşme faaliyetleri sonucunda kent ve yakın çevresindeki yeşil alanlar yani geçirimli yüzeyler azalmakta, bitki örtüsü, su kütleleri ve tarım arazileri gibi doğal peyzaj alanları geçirimsiz yüzeylere ve kentsel altyapıya dönüşmekte, yapılaşmayla birlikte geçirimsiz sert zemin yüzeyler artmaktadır. Bu durum, yerel ve bölgesel ölçekte iklimi etkileyerek, kentsel ve kırsal alanlar arasında sıcaklık farklarının ortaya çıkmasıyla tanımlanan kentsel ısı adası oluşumunu tetiklemekte ve nihayetinde çevre koşulları ve ekolojik denge olumsuz etkilenmektedir (Nakata & Souza, 2013; Zhou vd., 2014; Yao vd., 2017; Dai vd., 2018). Bu bağlamda, kentleşme ve sanayileşme ile birlikte ortaya çıkan ve son yıllarda sıklıkla mikroklimatik bir çevresel sorun olarak gözlemlenen kentsel ısı adası (KIA) etkisi; yüksek yoğunluklu geçirimsiz yüzey alanlarına sahip kentlerde ölçülen ve hissedilen sıcaklık değerinin, bitki yoğunluğunun fazla olduğu kırsal alanlarda ölçülen ve hissedilen sıcaklık değerinden 3-4 °C farklılık göstermesi anlamına gelmektedir (Howard, 1833; Zhou vd., 2016). Yüksek sıcaklık, düşük bağıl nem, düşük rüzgâr hızı ve bulutsuzluk gibi meteorolojik veriler (Oke, 1973; Landsberg, 1981; Jonsson vd., 2004; Weng & Yang, 2006) kentsel ısı adasını etkileyen faktörlerdir (Jonsson vd., 2004; Gago vd., 2013). Kentsel ısı adası da, yapılı çevreler başta olmak üzere kentleri; enerji tüketimi, toprak, su sistemi gibi pek çok alanda etkilemektedir (Santamouris vd., 2015).

Esasında her kentin arazi kullanımı ve yüzey özelliklerindeki farklılıklar nedeniyle, kentsel alan içerisindeki sıcaklık farklılıkları değişkenlik göstermektedir (Oke, 1973; Gago vd., 2013; Yuan vd., 2017). Bilhassa, sera gazı emisyonları ile beton zeminler, yollar, metal yüzeyler, cam cepheli yapılar gibi antropojenik yüzeylerin neden olduğu etkiler, kentsel alanlardaki sıcaklık artışının temel faktörleri olarak öne çıkmaktadır. Bu unsurlar, yüzey enerji dengesini bozarak sıcaklık değişikliklerine ve KIA yoğunluğunun artmasına yol açmaktadır. Keza bu durum, kentsel ve kırsal alanlar arasındaki iklimsel farklılıkları da belirgin şekilde etkilemektedir (Wemegah, 2020). Nitekim, kentlerde yer alan yeşil alanlar ile tarım ve orman alanlarının yerini binalar, sokaklar, otoparklar, yollar ve kanalizasyonlar gibi geçirimsiz yüzeylerin alması; radyasyon, termal, nem, pürüzlülük ve emisyon özelliklerinde değişikliklerin yaşanmasına, yüzey akışının azalmasına ve yüzey ısısının da artmasına yol açmaktadır (Mathew vd., 2016; Chapman vd., 2017). Oysa kentlerde yer alan yeşil alanlar, diğer bir deyişle geçirimli yüzeyler, yüzey akış sularını toprağın alt katmanlarına ve yer altı su kaynaklarına ileterek su döngüsü üzerindeki iklim değişikliği etkilerinin azaltılmasına, erozyonun önlenmesine, hava kalitesinin iyileştirilmesine, sera gazı etkilerinin azaltılmasına ve sağlıklı kentsel alanların oluşturulmasına katkı sağlamaktadır (Foster vd., 2011; Tikansak, 2014; Carter vd., 2018; Ersöz vd., 2022).

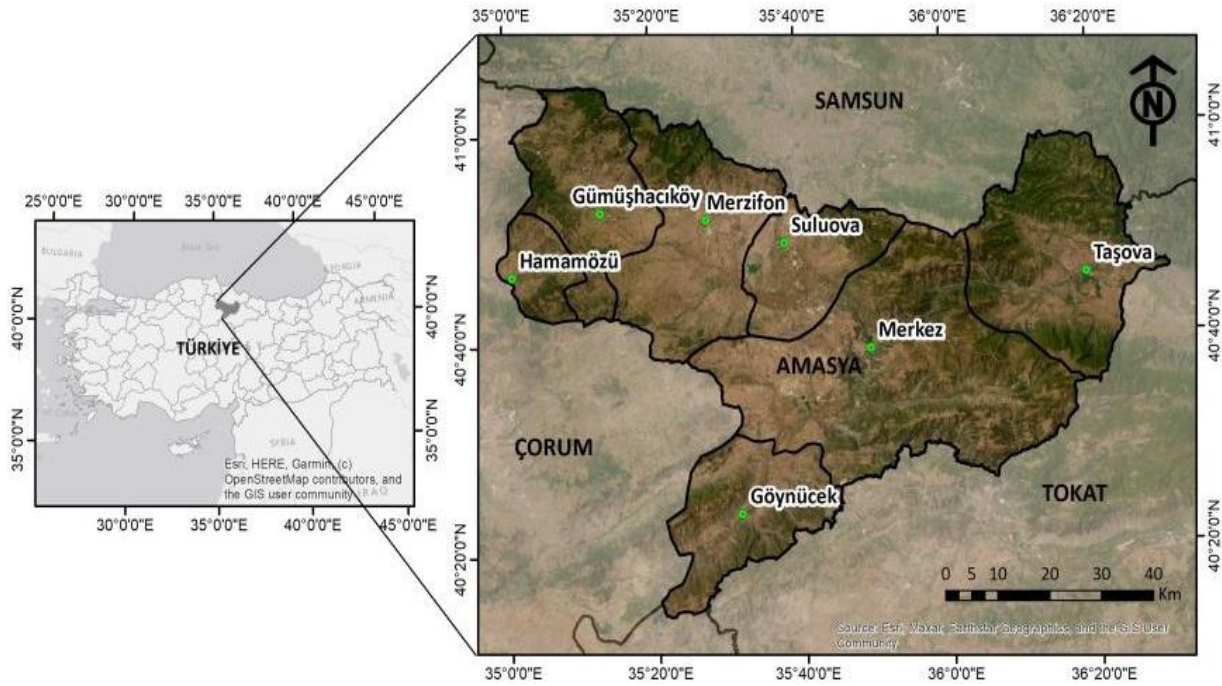
Günümüzde kentlerde yaşayan insan nüfusu verilerine göre, 7.6 milyar olan dünya nüfusunun yaklaşık %57'si (Dünya Bankası, 2022), 85,5 milyon olan Türkiye nüfusunun ise %77'si (Türkiye İstatistik Kurumu, 2022) kentlerde yaşamaktadır. Bununla birlikte, dünya nüfusunun 2030 yılında 8,6 milyara, 2050 yılında ise 9,8 milyara ulaşması beklenmektedir (United Nations, 2024). Bilhassa bu durumun küçük ve orta ölçekli kentlerin genişleyerek gelişigüzel büyümelerine neden olacağı düşünülmektedir (Das & Das, 2019). Bu da hem kent halkının refahı hem de kentsel sürdürülebilirliğin sağlanması adına acil önlemlerin uygulanması gerekliliğini ortaya koymaktadır. Öyle ki, hızla artan kentleşme AKAÖ değişimlerinin ivme kazanmasına neden olarak yalnızca kentsel alanlarda termal ısı stresi yaratmakla kalmamakta, aynı zamanda kent halkının yaşam kalitesini de olumsuz etkilemektedir. Öte taraftan, kentsel alanlardaki çevresel bozulmaların altyapı gelişimi ile de yakından ilişkisi bulunmaktadır (Das & Das, 2020). Bu nedenle, hızla kentleşen bölgelerde geçirimli ve geçirimsiz yüzeylerin analizi, kentsel yüzey ısı adası etkilerinin hafifletilmesi ve sürdürülebilir arazi kullanım planlama stratejilerinin geliştirilmesi açısından önemli bir gösterge niteliği taşımaktadır. Geçirimli ve geçirimsiz yüzey alanları arasındaki fark, yeryüzü sıcaklığı üzerinden uzaktan algılama verilerinden elde edilen görüntü işleme teknikleriyle hesaplanmakta ve farklı sınıflandırma yöntemleri kullanılarak, uydu görüntülerinden yeryüzü sıcaklığını etkileyen yüzey bilgilerini içeren AKAÖ haritaları üretilebilmektedir (Yıldız & Kavzoğlu, 2012; Armour, 2014; Gawuc & Struzewska, 2016; Korkut vd., 2016; Ersoy Tonyaloğlu, 2019; Arda, 2020; Çalhan & Özelkan, 2022; Özmekik vd., 2022;

Topal, 2023). Bu kapsam çerçevesinde bu çalışmada, Amasya il bütününde geçirimli ve geçirimsiz yüzeylerde meydana gelen değişimin tespit edilmesi amaçlanmıştır. Çalışmada 2006, 2009, 2012, 2015 ve 2018 yıllarına ait Copernicus Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) verileri kullanılmıştır. Yapılan analizler doğrultusunda elde edilen sonuçlar ışığında 2030 yılı için gelecek tahmininde bulunularak sürdürülebilir arazi kullanım planlamasına yönelik öneriler sunulmuştur.

2. Materyal ve Metot

2.1. Çalışma Alanı

Çalışma alanı olarak, orta ölçekli bir kent olan Amasya ili seçilmiştir. Amasya ili, Karadeniz Bölgesi'nin Orta Karadeniz Bölümünde $34^{\circ} 57' 06''$ - $36^{\circ} 31' 53''$ Doğu Boyamları ile $41^{\circ} 04' 54''$ - $40^{\circ} 16' 16''$ Kuzey Enlemleri arasında yer almaktadır. Merkez, Suluova, Merzifon, Gümüşhacıköy, Taşova, Göynücek ve Hamamözü olmak üzere toplam 7 ilçeden oluşmaktadır. İl, doğudan Tokat, güneyden Tokat ve Yozgat, batıdan Çorum, kuzeyden Samsun illeri ile çevrili olup, yüzölçümü 5.628 km^2 'dir (Şekil 1). Amasya ilinin 2006 yılındaki nüfusu 328.674, 2012 yılındaki nüfusu 322.283'tür. 2018 yılındaki nüfusu ise geçen 6 yıllık zaman diliminde %8.3 oranında artış göstererek 337.508 olmuştur (Türkiye İstatistik Kurumu, 2024a). 2006-2018 yılları arasında Merzifon ve Merkez ilçelerinde nüfus artışı olurken Göynücek, Gümüşhacıköy, Hamamözü, Suluova ve Taşova ilçelerinde nüfus azalmıştır. 2018 yılı nüfus büyüklüklerine göre ilçe sıralaması Merkez, Merzifon, Suluova, Taşova, Gümüşhacıköy, Göynücek ve Hamamözü şeklindedir (Tablo 1).



Şekil 1. Çalışma alanı

Tablo 1. Amasya ili ilçelerinin 2006, 2009, 2012, 2015 ve 2018 yıllarına ait nüfus bilgileri (Türkiye İstatistik Kurumu, 2024a)

İlçe	2006 Yılı	2009 Yılı	2012 Yılı	2015 Yılı	2018 Yılı	Değişim Oranı (%)
Merkez	132.646	132.010	133.133	137.549	149.084	+12.4
Göynücek	13.425	12.358	11.432	10.443	10.703	-20.3
Gümüşhacıköy	25.632	25.235	23.673	22.943	23.734	-7.4
Hamamözü	5.264	4.646	4.335	3.873	3.955	-24.0
Merzifon	69.093	68.950	70.167	70.132	71.916	+4.1
Suluova	47.428	47.448	46.479	46.485	46.608	-1.7
Taşova	35.186	33.621	33.064	30.742	31.508	-10.4
Toplam	328.674	324.268	322.283	322.167	337.508	+2.7

Amasya ili, iklim indislerine göre yarı kurak-az nemli iklim tipi içerisine girmektedir. İl ve yakın çevresinde mayıs ile kasım ayları arası kurak, yılın diğer yarısı ise nemli geçmektedir (Meteoroloji Genel Müdürlüğü, 2024a). Yağış rejimi bakımından ise İç Anadolu karasal geçiş tipi özelliğine sahiptir (T.C. Amasya Valiliği İl Afet ve Acil Durum Müdürlüğü, 2021). Merzifon, Suluova, Gümüşhacıköy ve Hamamözü ilçeleri, ilin genel iklim özelliklerini yansıtırken, Merkez, Taşova ve Göynücek ilçelerinde karasal iklim özellikleri daha belirgin şekilde görülmektedir (T.C. Amasya İl Kültür ve Turizm Müdürlüğü, 2024). Meteoroloji Genel Müdürlüğü'nün uzun yıllar içerisinde (1961-2023) gerçekleşen istatistikî değerleri göz önünde bulundurulduğunda, Amasya ilinde ortalama olarak en az yağış ağustos ayında, en fazla yağış nisan aylarında görülmektedir. Temmuz ayı en yüksek (45 °C) sıcaklığa, Ocak ayı en düşük (-21,0 °C) sıcaklığa sahiptir. Ortalama güneşlenme süresi ise en fazla Temmuz, en az Aralık aylarında görülmektedir (Meteoroloji Genel Müdürlüğü, 2024b).

2.2. Kullanılan Veri Kaynakları ve Analiz

2.2.1. Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) Derecelerinin Belirlenmesi

Çalışmada verilerin işlenmesi ve analizlerin gerçekleştirilmesinde ArcGIS 10.8 yazılımından yararlanılmıştır. Veri seti olarak; Copernicus Land Monitoring Service (CLMS) (Copernicus Arazi Gözlem Hizmetleri) web sitesinden açık erişimli ve ücretsiz olarak temin edilen High Resolution Layer Imperviousness (HRL IMD) (Yüksek Çözünürlüklü Katman Geçirimsizlik) verileri kullanılmıştır. Copernicus, Avrupa Birliği'nin Dünya Gözlem Programı'dır. Uydu Dünya gözlemi ve yerinde (uzay dışı) verilere dayalı bilgi hizmetleri sağlamaktadır. CLMS, Avrupa'da ve dünyanın dört bir yanındaki kullanıcılara yüksek çözünürlüklü katmanlar ile arazi örtüsü/arazi kullanımı ve değişimleri, bitki örtüsü durumu, su döngüsü vb. hakkında coğrafi bilgiler sunmaktadır. Çalışmada kullanılan HRL IMD verileri ile yapılan analizlerin doğruluk değerlendirmeleri için, kullanıcı ve üretici doğruluğu en az %90 olarak bildirilmektedir (European Union Copernicus Land Monitoring Service, 2024).

İlgili veriler, Amasya ili özelinde temin edilerek kullanılmıştır. HRL IMD verileri raster ürün olup, her pikseldeki geçirimsizlik derecesini tahmin eder. Bu veri seti 2006, 2009, 2012, 2015 ve 2018 yıllarını kapsamakta olup, 2006-2015 yılları için 20 m ve 2018 yılı için 10 m mekânsal çözünürlüğe sahiptir. Burada her piksel geçirimsizlik durumu açısından %0 ve %100 arasında değerlerle temsil edilmekte olup, 0 değeri tüm geçirimsiz olmayan veya geçirgen yüzeyleri (bitki örtüsü, çıplak geçirgen toprak yüzeyi gibi) göstermektedir. %1 ile %100 arasındaki değerler ise farklı oranlarda geçirimsizlik derecesini temsil etmektedir (European Union Copernicus Land Monitoring Service, 2024). Konut alanları, havaalanları, limanlar, demiryolu sahaları, otoparklar, yollar, inşaat alanları, sanayi alanları, fabrikalar, üretim ve dağıtım merkezi, suni çimle kaplı spor sahaları, seralar, kalıcı plastik kaplı toprak örtüsü vb. geçirimsiz yüzeyleri oluştururken; maden alanları, taş ocakları, kum alanları, kum çukurları, çöplük alanlar, bitki örtüsü olmayan ya da seyrek bitki örtüsüne sahip alanlar, bitki örtüsü olmayan tarım alanları, ekilebilir arazi, üzüm bağları, çim alanlar, yeşil çatılar vb. ise geçirimli yüzeyleri oluşturmaktadır (European Union Copernicus Land Monitoring Service, 2018). İlgili verilerin analizler için hazırlanmasında öncelikle European Terrestrial Reference System 1989 (ETRS89) Lambert Azimuthal Equal Area (LAEA) olan projeksiyon sistemi WGS 1984 projeksiyon sistemine dönüştürülmüştür. Ayrıca, her yıla ait veri çözünürlüklerinin aynı olması için 2018 yılına ait 10 m mekânsal çözünürlüklü veri, resample aracı kullanılarak 20 m olarak düzenlenmiştir.

Önceki çalışmalara bakıldığında, araştırmacıların IDM sınıflandırmalarını farklı şekillerde ele aldıkları görülmektedir (Tablo 2). Örneğin, Drašković (2021), Bosna Hersek'i ele aldığı ve Sarajevo, Banja Luka, Tuzla, Mostar ve Zenica'yı irdelediği çalışmasında IDM değerlerini >%80, %50-80, %30-50, %10-30 ve <%10 şeklinde sınıflandırmıştır. Liu vd. (2019) ise Paris, Ankara, Madrid ve Lizbon'u, Topal ve Yılmaz (2024) Tekirdağ'ı ele aldıkları çalışmalarında IDM değerlerinin %1 ile %100 arasında olduğu alanları "yapılaşmış alanlar" olarak, %0'a eşit olduğu alanları ise "yapılaşmamış alanlar" olarak belirlemişlerdir. Bu çalışmada ise, analizlerde daha anlamlı sonuçlar elde edebilmek için tüm geçirgen yüzeyleri ifade eden 0 değeri tek bir sınıf altında toplanmıştır. %1 ile %100 arasındaki değerler ise; %1 ile %33 arasındaki geçirimsizlik (düşük), %33 ile %66 arasındaki geçirimsizlik (orta) ve %66-%100 arasındaki geçirimsizlik (yüksek) olmak üzere 3 sınıf altında toplanmıştır.

Tablo 2. Literatüre dayalı IDM sınıflandırmaları

IDM Sınıflandırması	İncelenen Şehirler	Kaynak
%1-100 – Yapılaşmış Alanlar	Paris, Ankara, Madrid ve Lizbon	Liu vd. (2019)
%0 – Yapılaşmamış Alanlar	Tekirdağ	Topal & Yılmaz (2024)
>%80, %50-80, %30-50, %10-30, <%10	Bosna Hersek, Sarajevo, Banja Luka, Tuzla, Mostar, Zenica	Drašković (2021)

2.2.2. Regresyon Analizi

Mühendislik problemlerinin çözümünde, çoğu değişkenin birbiriyle ilişkili olduğu görülmektedir. İstatistiksel olarak, bir değişkendeki değişiklik diğer değişkenleri aynı ölçüde etkilemez. Bu nedenle, değişkenler arasındaki sebep-sonuç ilişkilerinin belirlenmesi önemlidir. Bu ilişkiler, matematiksel olarak regresyon analizi kullanılarak ortaya çıkarılabilir. Regresyon analizi, iki veya daha fazla bağımlı ve bağımsız değişken arasındaki ilişkiyi incelemek amacıyla kullanılan bir istatistiksel yöntemdir (Tolon & Tosunoğlu, 2008).

Doğrusal regresyon analizi basit doğrusal regresyon ve çoklu doğrusal regresyon olarak iki başlık altında incelenmektedir. Regresyon analizi tek bir değişkenin olduğu durumlarda tek değişkenli doğrusal regresyon, birden fazla değişkenin olduğu durumlarda ise çok değişkenli doğrusal regresyon olarak adlandırılır. Lineer regresyon analizi ile, bilinen ya da saptanabilen değişken(ler) kullanılarak belirlenmek istenen bir diğer değişkeni tahmin eden bir tahmin modeli oluşturulur. Eşitlik (1)'de basit regresyon model denkleminin görülmektedir (Yan & Su, 2009).

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

Eşitlik (1)'e göre; y bağımlı değişkeni, β_0 regresyon sabitini, β_1 regresyon katsayısını, x bağımsız değişkeni, ε hata terimini temsil etmektedir.

Doğrusal olmayan, diğer bir deyişle bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki bulunmadığı durumlarda, regresyon denkleminin çeşitli regresyon fonksiyonları ile ifade edilebilir. Bu durumlarda basit lineer regresyon analizi yerine "Polinom regresyon modeli" kullanılabilir. Tek değişkenli polinom regresyonda kullanılan model denkleminin Eşitlik (2)'de verilmiştir (Ostertagová, 2012).

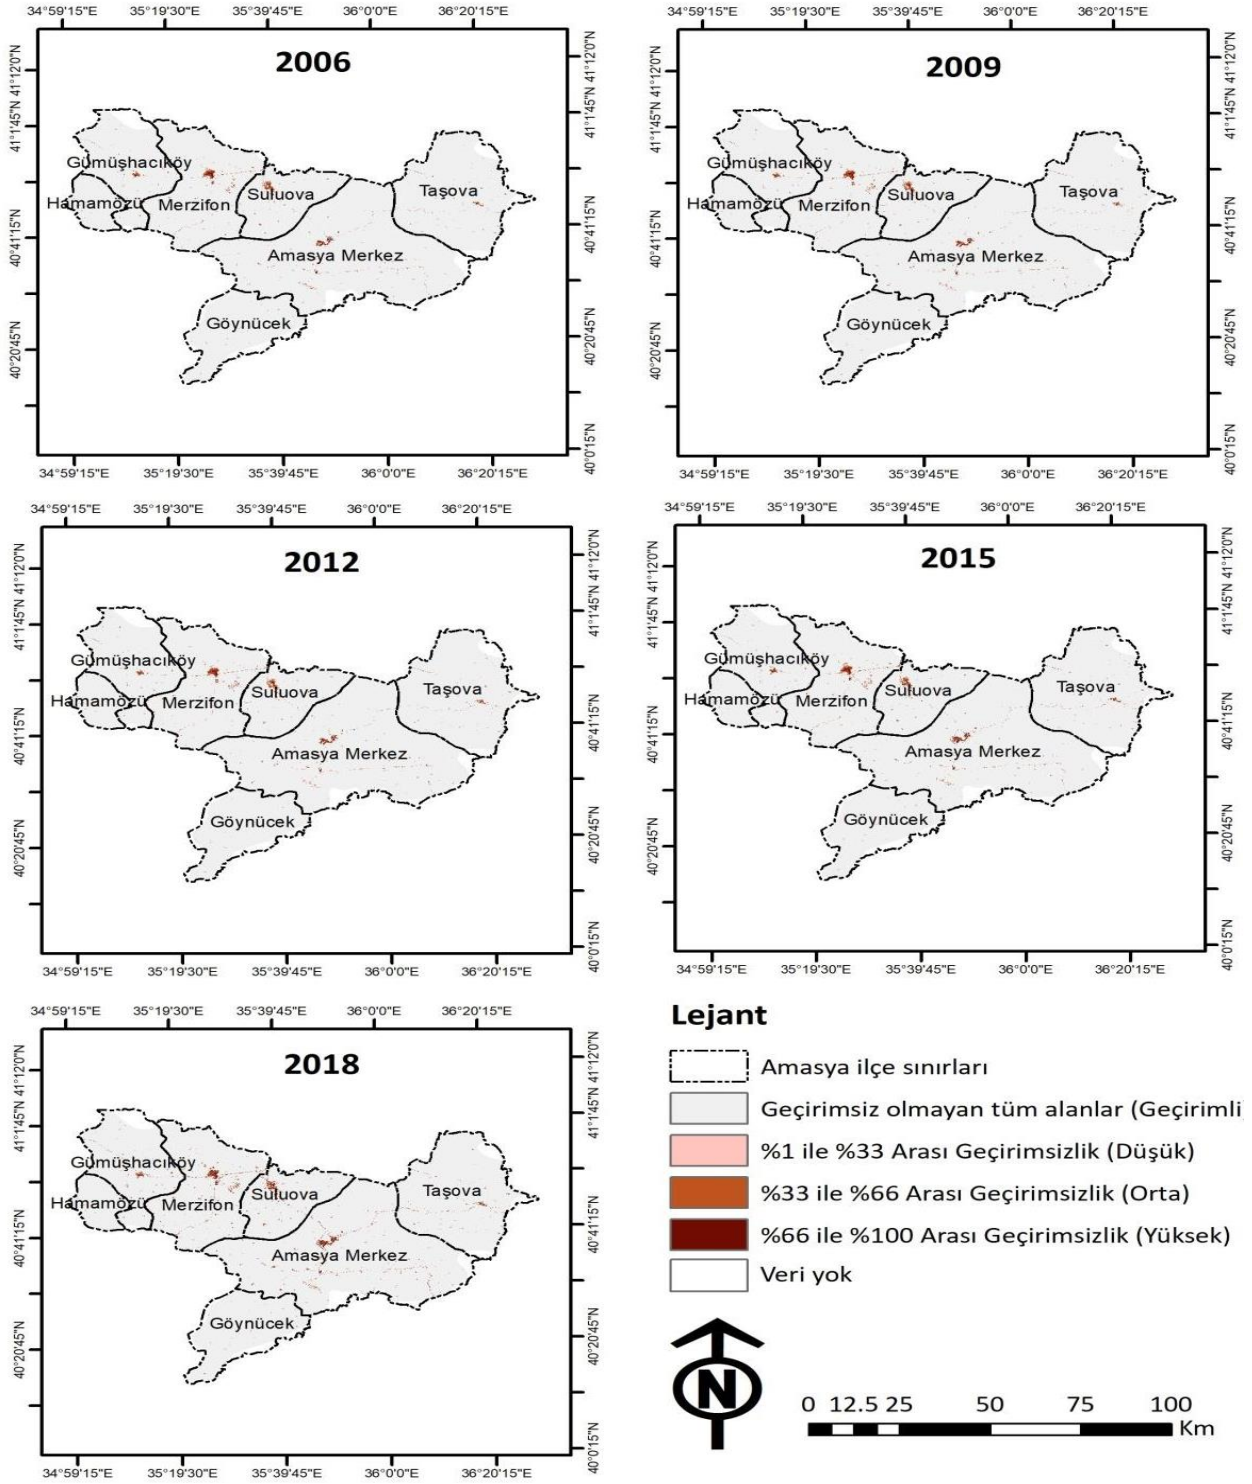
$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \dots + \beta_n x_i^n + \varepsilon_i \quad i = 1, 2, \dots \quad (2)$$

Eşitlik (2)'ye göre; n polinom derecesini ifade eder. Çalışmada yapılan istatistiksel hesaplamalar Microsoft Excel yazılımı kullanılarak gerçekleştirilmiştir.

3. Bulgular

3.1. HRL IMD Verilerine İlişkin Bulgular

Amasya il bütününde 2006-2018 yılları arasında geçirimlilik derecesinde (Şekil 2) meydana gelen değişimin incelendiği bu çalışmada, çalışma alanı araç ve yaya yollarından, demiryolundan, sanayi, tarım, konut, eğitim, sağlık, çocuk oyun, rekreasyon alanlarından, yeşil alanlardan, orman alanından, mera alanından, çıplak araziden ve yapılı çevreden (T.C. Amasya Valiliği Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü, 2024) oluşmaktadır. Yıllara bağlı olarak farklı geçirimlilik derecelerine göre alanların (hektar cinsinden) miktarları ile 2006-2018 yılları arasındaki değişim oranları Tablo 3'te verilmiştir.



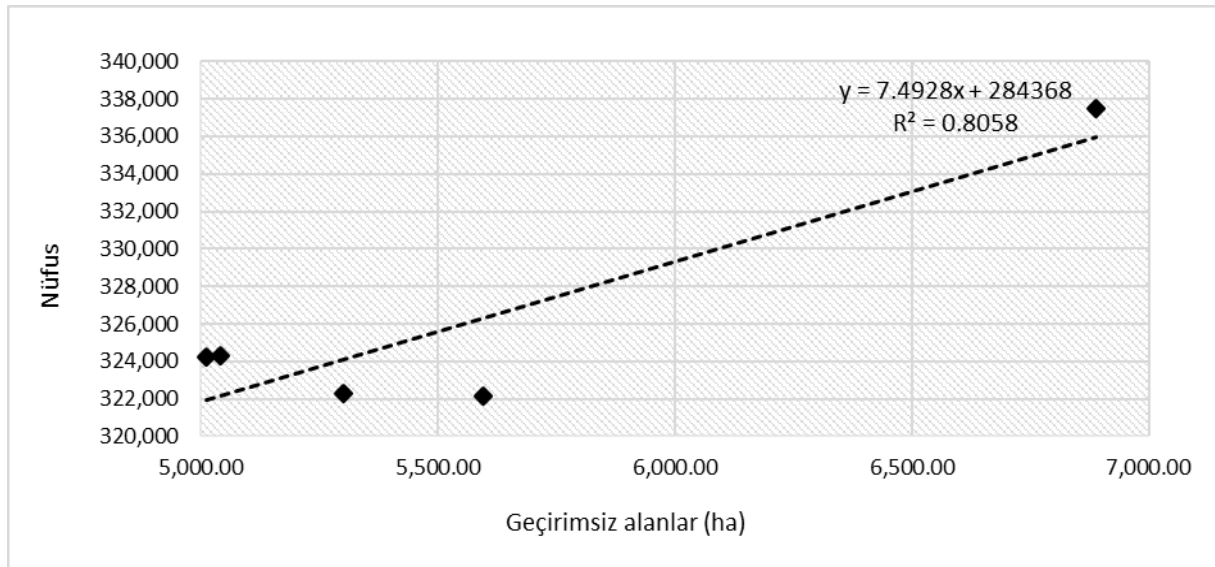
Şekil 2. Amasya il bütününde 2006-2018 yılları arasında geçirimsizlik derecesini gösteren haritalar

Buna göre, Amasya il bütününde yüzey sularının kolaylıkla drene edilmesine imkân tanıyan çim, çalı, ağaç vb. bitki örtüsü ve toprakla kaplı geçirimli yüzeylerin (geçirimsiz olmayan tüm alanlar %0) 2006 yılında 531,012.59 ha iken %0.37'lik küçülme göstererek 2018 yılında 529,072.94 ha olduğu belirlenmiştir (Şekil 2, Tablo 3). Bu durum, doğal alanların bir kısmının geçirimsiz yüzeyler haline geldiğini göstermektedir. Geçirimsizlik derecesi %1%-%33 arasında olan düşük geçirimli yüzeyler, 12 yıllık süreç içerisinde %5.31'lik küçülme ile 968.56 ha olmuştur. Bu değişim, düşük geçirimsizlikteki alanların kentsel gelişim alanları ya da yüksek geçirimsizlik seviyelerine dönüşmüş olabileceğini göstermektedir. Orta geçirimsiz yüzeyler %0.20'lik büyüme göstererek 2,744.81 ha'dan 2,750.27 ha olmuştur.

Bu artış, sınırlı bir genişleme olduğunu işaret etmektedir. Geçirimsizlik derecesi %66-%100 arasında olan asfalt, beton gibi yüksek geçirimsiz yüzeyler ise, süreç içerisinde %154.41'lik artış ile 3,168.69 ha olmuştur. Bu değişim, kentsel alanların genişlemesi ve yüksek geçirimsiz yüzeylerin hızlı bir şekilde arttığını ortaya koymaktadır. Yüksek geçirimsiz yüzeylerdeki bu artış, halihazırda geçirimsiz olan bazı yüzeylerin geçirimsizlik derecelerinin artış gösterdiğini ortaya koymuştur. Bu da bu alanlarda yapılaşmaya yönelik birtakım faaliyetlerin arttığını veya hâlihazırda inşaat halinde olan bu alanların yapılaşmasının kısmen veya tamamen tamamlandığını göstermektedir. İlgili yıllar için saptanan geçirimsiz yüzey alanlarının, yine ilgili yıllara ait nüfus verileri ile ilişkileri korelasyon analizi ile değerlendirilmiştir (Şekil 3). Buna göre geçirimsiz alanlar ile nüfus verileri arasında pozitif korelasyon ilişkisi olduğu görülmüştür. Geçirimsiz alanlar ile nüfus verileri arasındaki korelasyon katsayısı 0.8977 olarak hesaplanmıştır. Bu yüksek korelasyon değeri, nüfus artışı ile yeni yerleşim yeri ihtiyaçlarının ortaya çıktığını bu doğrultuda da yapılaşma ve dolayısıyla kentleşme faaliyetlerinin artış gösterdiğini düşündürmektedir.


Tablo 3. Amasya il bütününde 2006, 2009, 2012, 2015 ve 2018 yıllarındaki farklı geçirimsizlik derecelerindeki alanlar ve 2006-2018 yılları arasındaki değişim oranları (%)

Geçirimsizlik Derecesi (%)	Geçirimsizlik Durumu	Geçirimsizlik Seviyesi	Alan (ha)					2006-2018 Δ (%)	
			2006	2009	2012	2015	2018		
%0	Geçirimsiz olmayan tüm alanlar	Geçirimli	531,012.59	530,984.23	530,724.99	530,428.86	529,072.94	-0.37	↔
%1-%33	%1 ile %33 Arası Geçirimsizlik	Düşük Geçirimsizlik	1,022.91	1,026.04	1,045.24	1,055.88	968.56	-5.31	↓
%33-%66	%33 ile %66 Arası Geçirimsizlik	Orta Geçirimsizlik	2,744.81	2,755.38	2,864.87	2,988.64	2,750.27	+0.20	↔
%66-%100	%66 ile %100 Arası Geçirimsizlik	Yüksek Geçirimsizlik	1,245.49	1,260.14	1,390.74	1,552.44	3,168.69	+154.41	↑



Şekil 3. Amasya ilinin 2006, 2009, 2012, 2015 ve 2018 yıllarındaki nüfus verileri ve geçirimsiz alanlar arasındaki korelasyon

Amasya ili, ilçeleri bazında ele alındığında ise, geçirimsizlik derecesine göre alanların yıllara bağlı durumları Şekil 4'te, 2006-2018 yılları arasındaki her bir geçirimsizlik derecesindeki alansal durum ve değişimlerin yüzdesel oranları Tablo 4'te verilmiştir.



Şekil 4. Amasya ilçelerinin 2006, 2009, 2012, 2015 ve 2018 yıllarındaki geçirimsiz ve farklı geçirimsizlik derecelerindeki arazi büyüklüklerini gösterir grafik

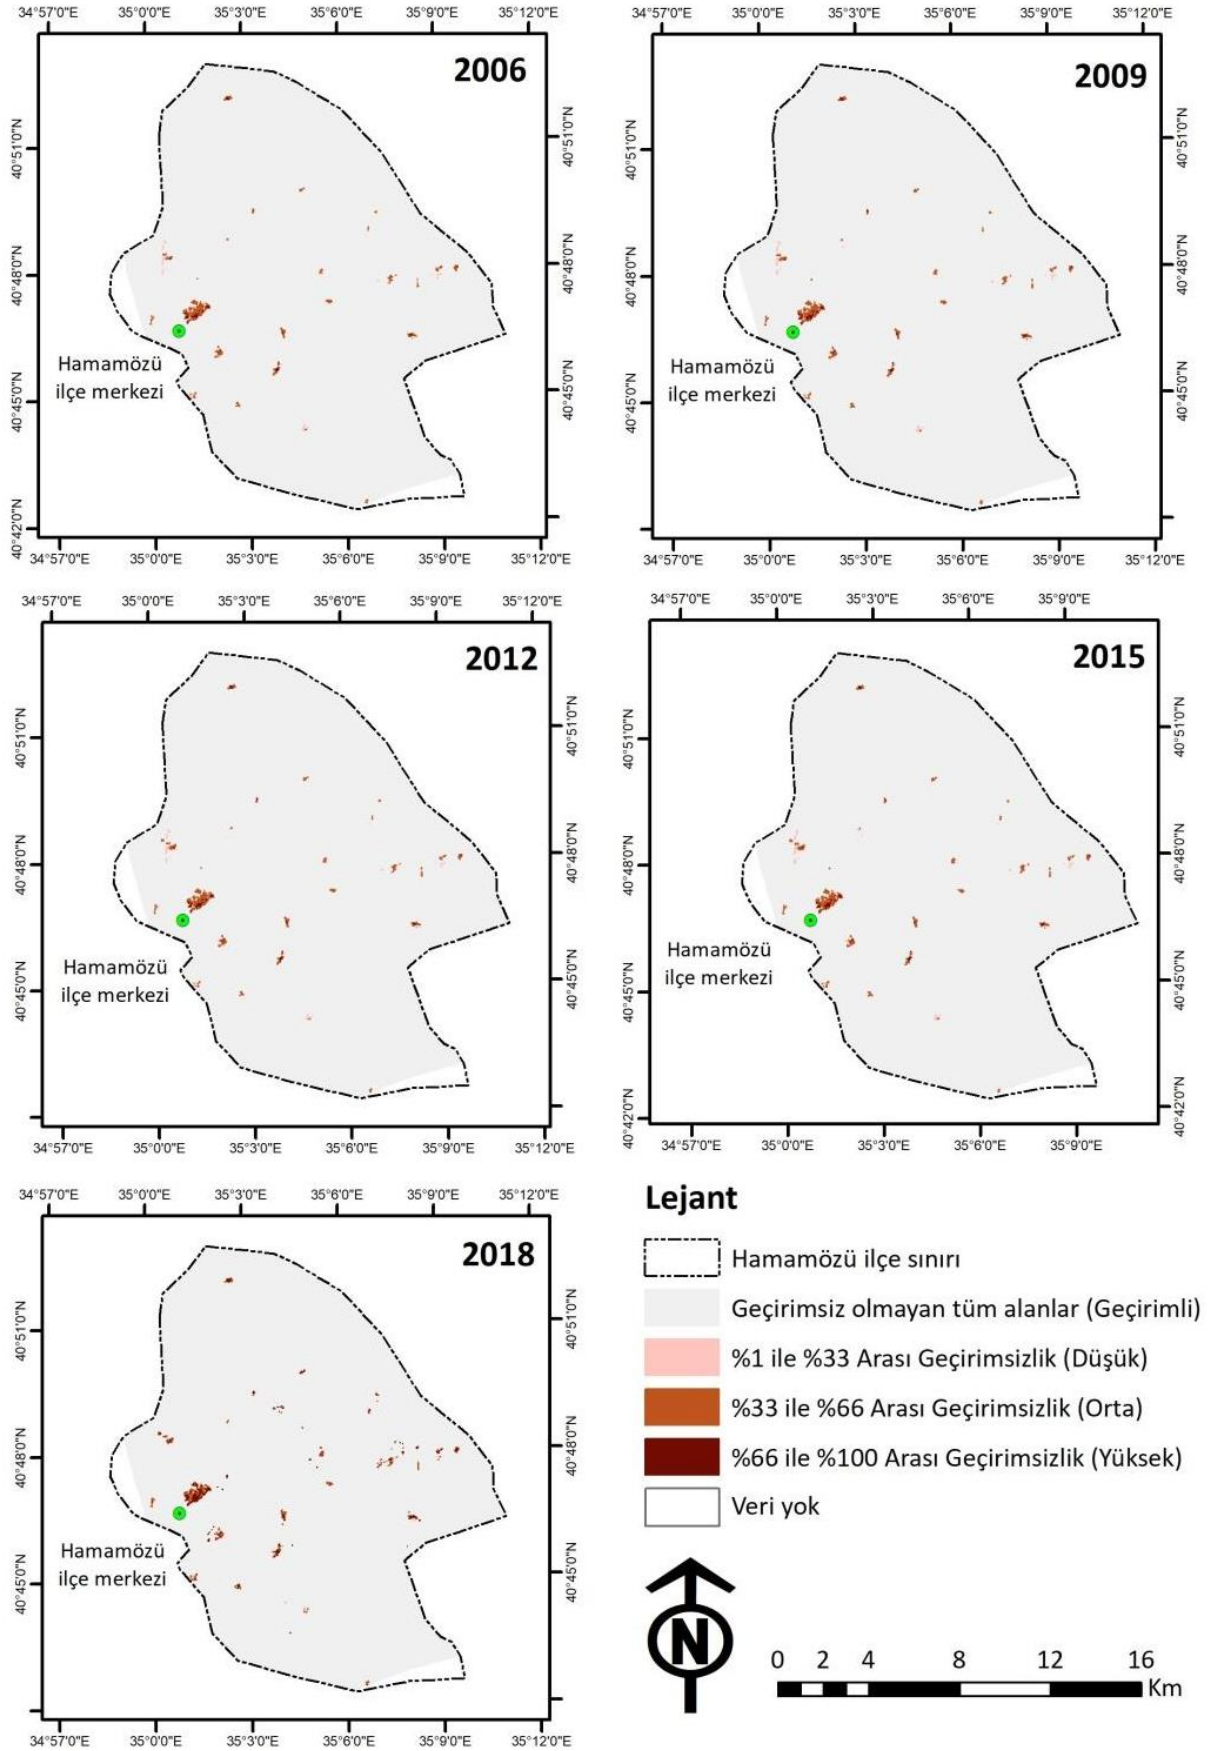
Tablo 4. Amasya ilçelerinin 2006-2018 yılları arasındaki geçirimsiz ve farklı geçirimsizlik derecelerindeki arazilerin değişim oranları (%)

İlçeler	Geçirimsizlik Derecesi (%)	2006 (ha)	2018 (ha)	Δ Değişim (%)	
Hamamözü	0%	20,363.81	20,350.85	0%	↔
	1%-33%	32.39	27.86	-14%	↓
	33%-66%	50.77	49.62	-2%	↓
	66%-100%	4.55	14.8	225%	↑
Gümüşhacıköy	0%	59,308.67	59,098.45	0%	↔
	1%-33%	93.57	116.32	24%	↑
	33%-66%	317.58	327.18	3%	↑
	66%-100%	91.28	248	172%	↑
Merzifon	0%	85,962.32	85,545.38	0%	↔
	1%-33%	241.98	206.26	-15%	↓
	33%-66%	777.70	677.88	-13%	↓
	66%-100%	380.08	914.10	141%	↑
Suluova	0%	46,327.19	46,064.95	-1%	↓
	1%-33%	166.04	123.71	-25%	↓
	33%-66%	510.90	463.29	-9%	↓
	66%-100%	168.68	507.35	201%	↑

Tablo 4'ün devamı

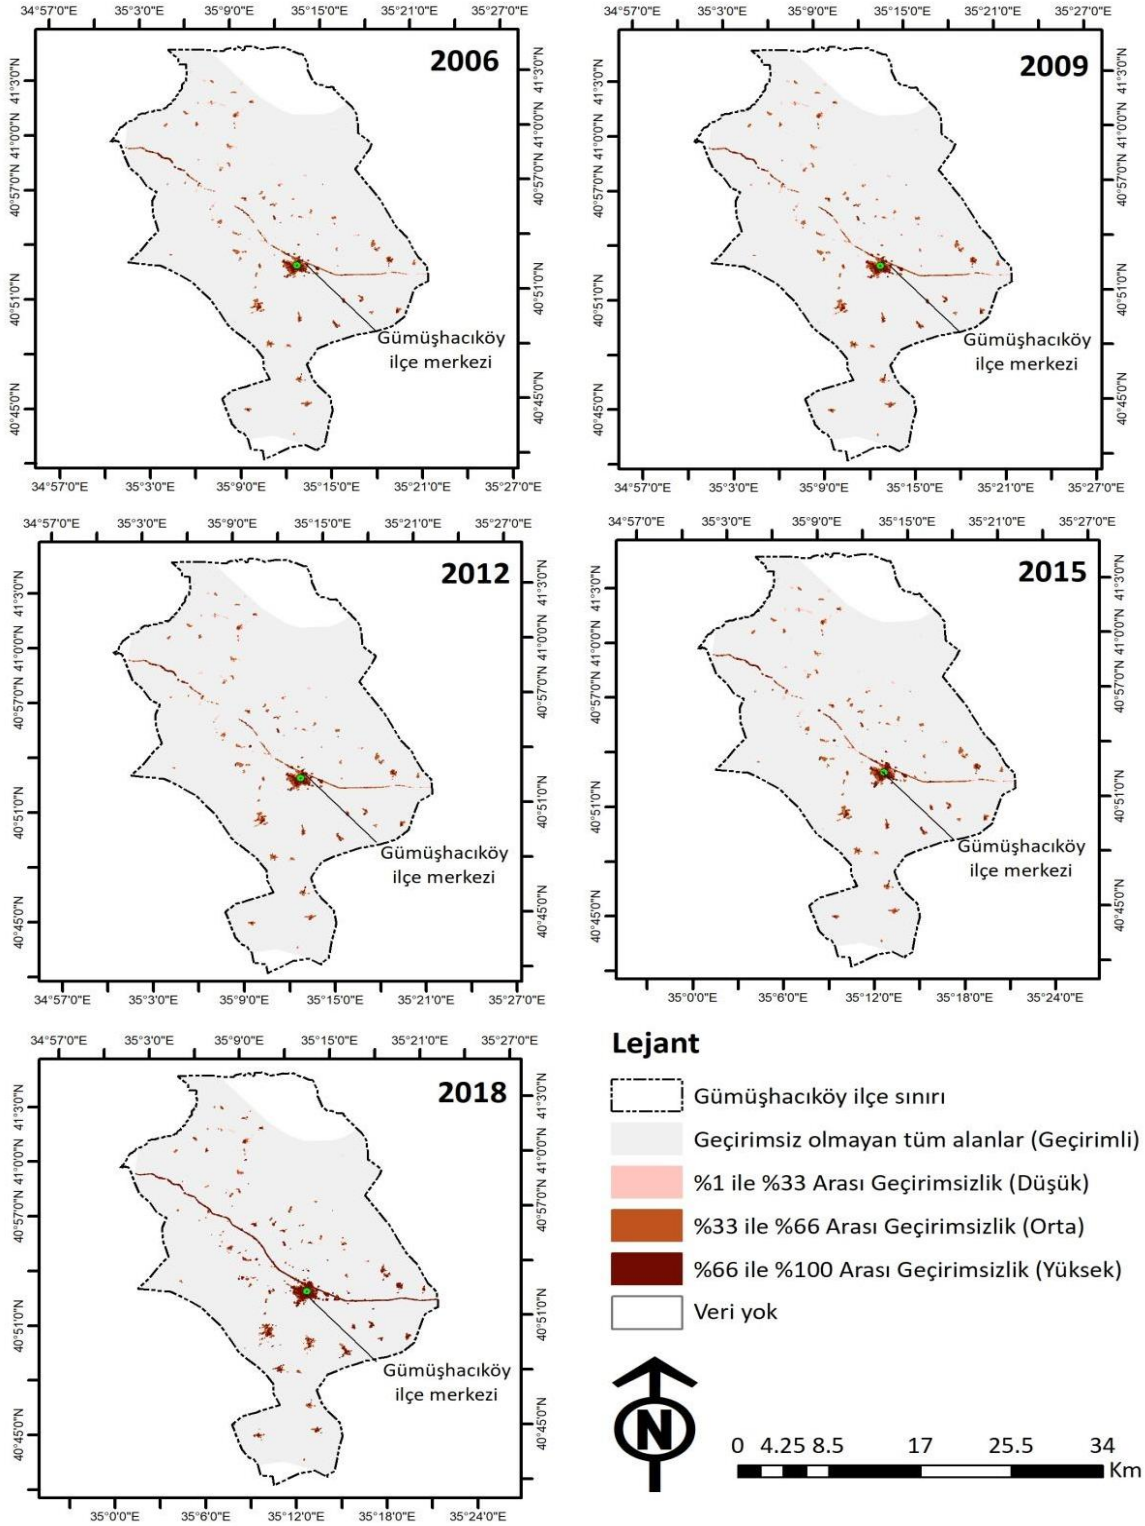
İlçeler	Geçirimsizlik Derecesi (%)	2006 (ha)	2018 (ha)	Δ Deđişim (%)	
Taşova	0%	93,845.99	93,656.23	0%	↔
	1%-33%	147.78	138.63	-6%	↓
	33%-66%	314.04	313.62	0%	↔
	66%-100%	81.02	254.95	215%	↑
Göynücek	0%	53,048.57	53,002.48	0%	↔
	1%-33%	72.51	65.29	-10%	↓
	33%-66%	73.03	85.04	16%	↑
	66%-100%	4.19	19.66	369%	↑
Merkez	0%	172,156.04	171,306.97	0%	↔
	1%-33%	268.63	290.49	8%	↑
	33%-66%	700.79	833.59	19%	↑
	66%-100%	515.71	1,209.64	135%	↑

Şekil 4 ve Tablo 4'e göre; Hamamözü ilçesinde 12 yıllık süreçte geçirimli yüzeyler yani doğal alanların 20,363.81 ha'dan 20,350.85 ha'a düştüğü görülmektedir. Bununla birlikte, geçirimsizlik derecesi %1-%33 arasında olan düşük dereceli geçirimsiz yüzeylerde %14'lük bir azalma görülürken, geçirimsizlik derecesi %33-%66 arasında olan orta dereceli geçirimsiz yüzeylerde %2'lik bir azalma, geçirimsizlik derecesi %66-%100 arasında olan asfalt, beton gibi yüksek geçirimsiz yüzeylerde ise %225'lik artış olduğu belirlenmiştir. Bu durum, Hamamözü ilçesindeki yapılaşmış alanların arttığına açık bir göstergesi olarak kabul edilebilir (Şekil 5).



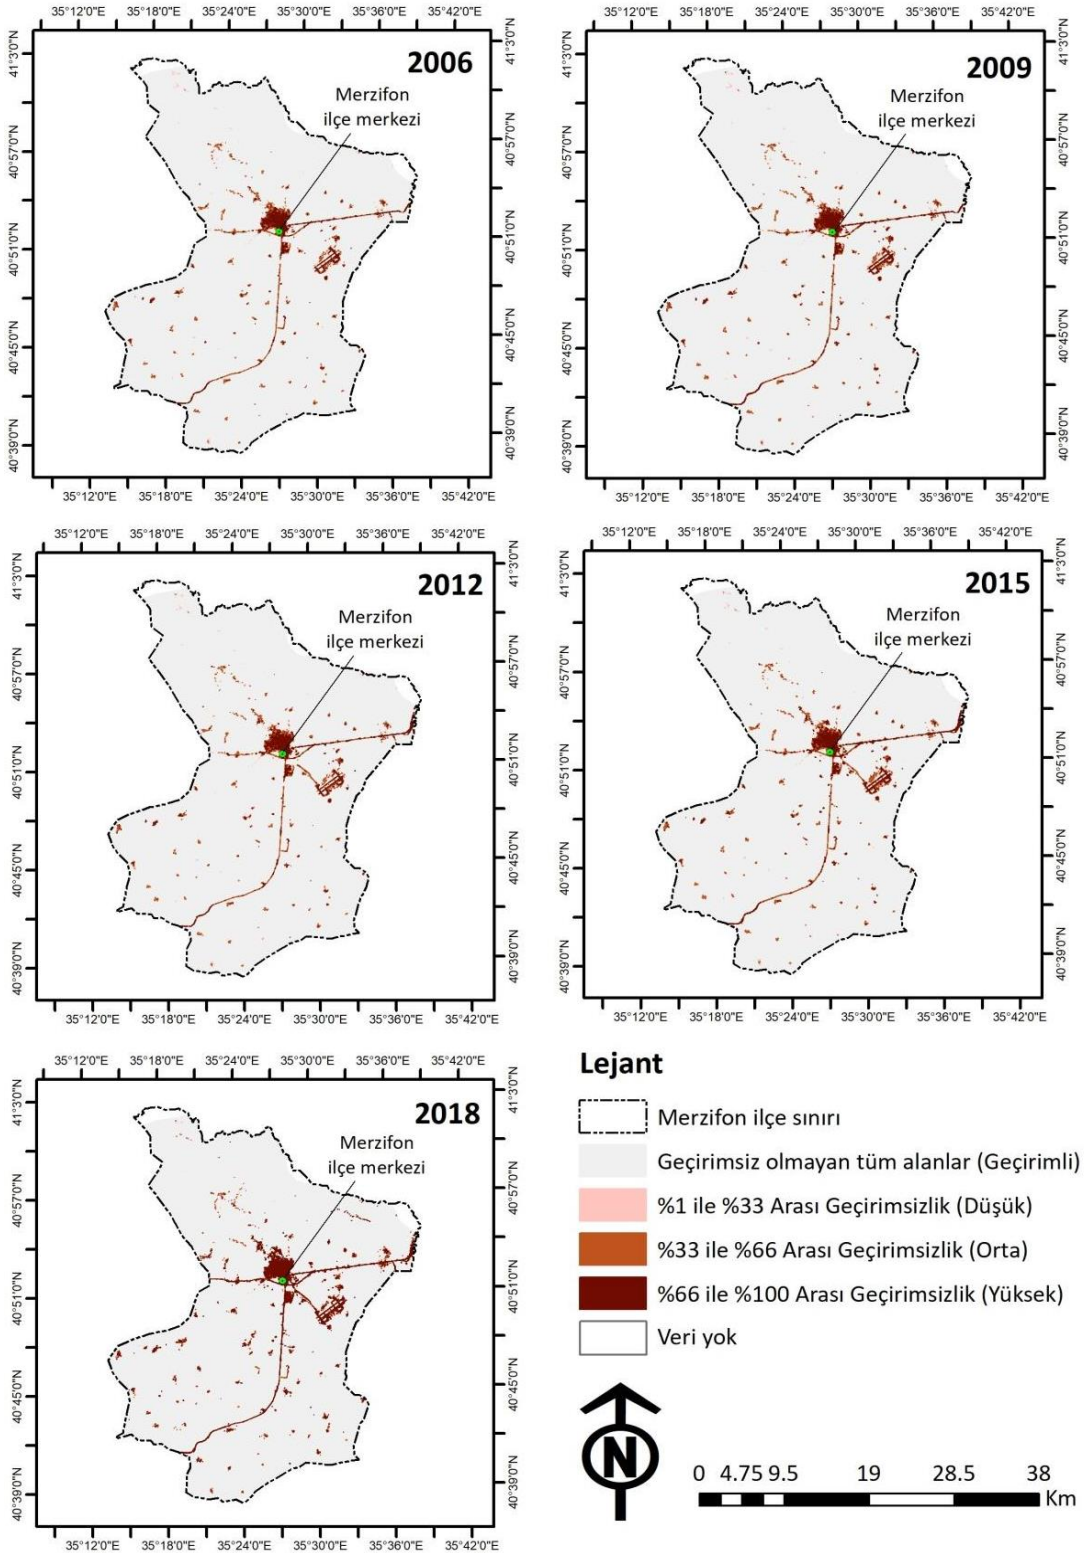
Şekil 5. Hamamözü ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Gümüşhacıköy ilçesinde de Hamamözü ilçesine benzer şekilde 2006 ile 2018 yılları arasında geçirimli yüzeyler 59,308.67 ha'dan 59,098.45 ha'ya düşmüştür. Geçirimsizlik derecesi %1-%33 arasında olan düşük dereceli geçirimsiz yüzeylerde %24 artış olmuş, geçirimsizlik derecesi %33-%66 arasında olan orta dereceli geçirimsiz yüzeylerde %3 artış yaşanmıştır. Bu sonuçlar düşük ve orta dereceli geçirimsiz derecelerindeki alanlarda bir genişleme olduğunu göstermektedir. Geçirimsizlik derecesi %66-%100 arasında olan yüksek dereceli geçirimsiz yüzeylerde ise %172'lik bir artış olduğu görülmekle birlikte, bu durumun da Gümüşhacıköy ilçesindeki artan kentleşme faaliyetleri ve altyapı gelişimiyle ilişkili olduğu söylenebilir (Şekil 6).



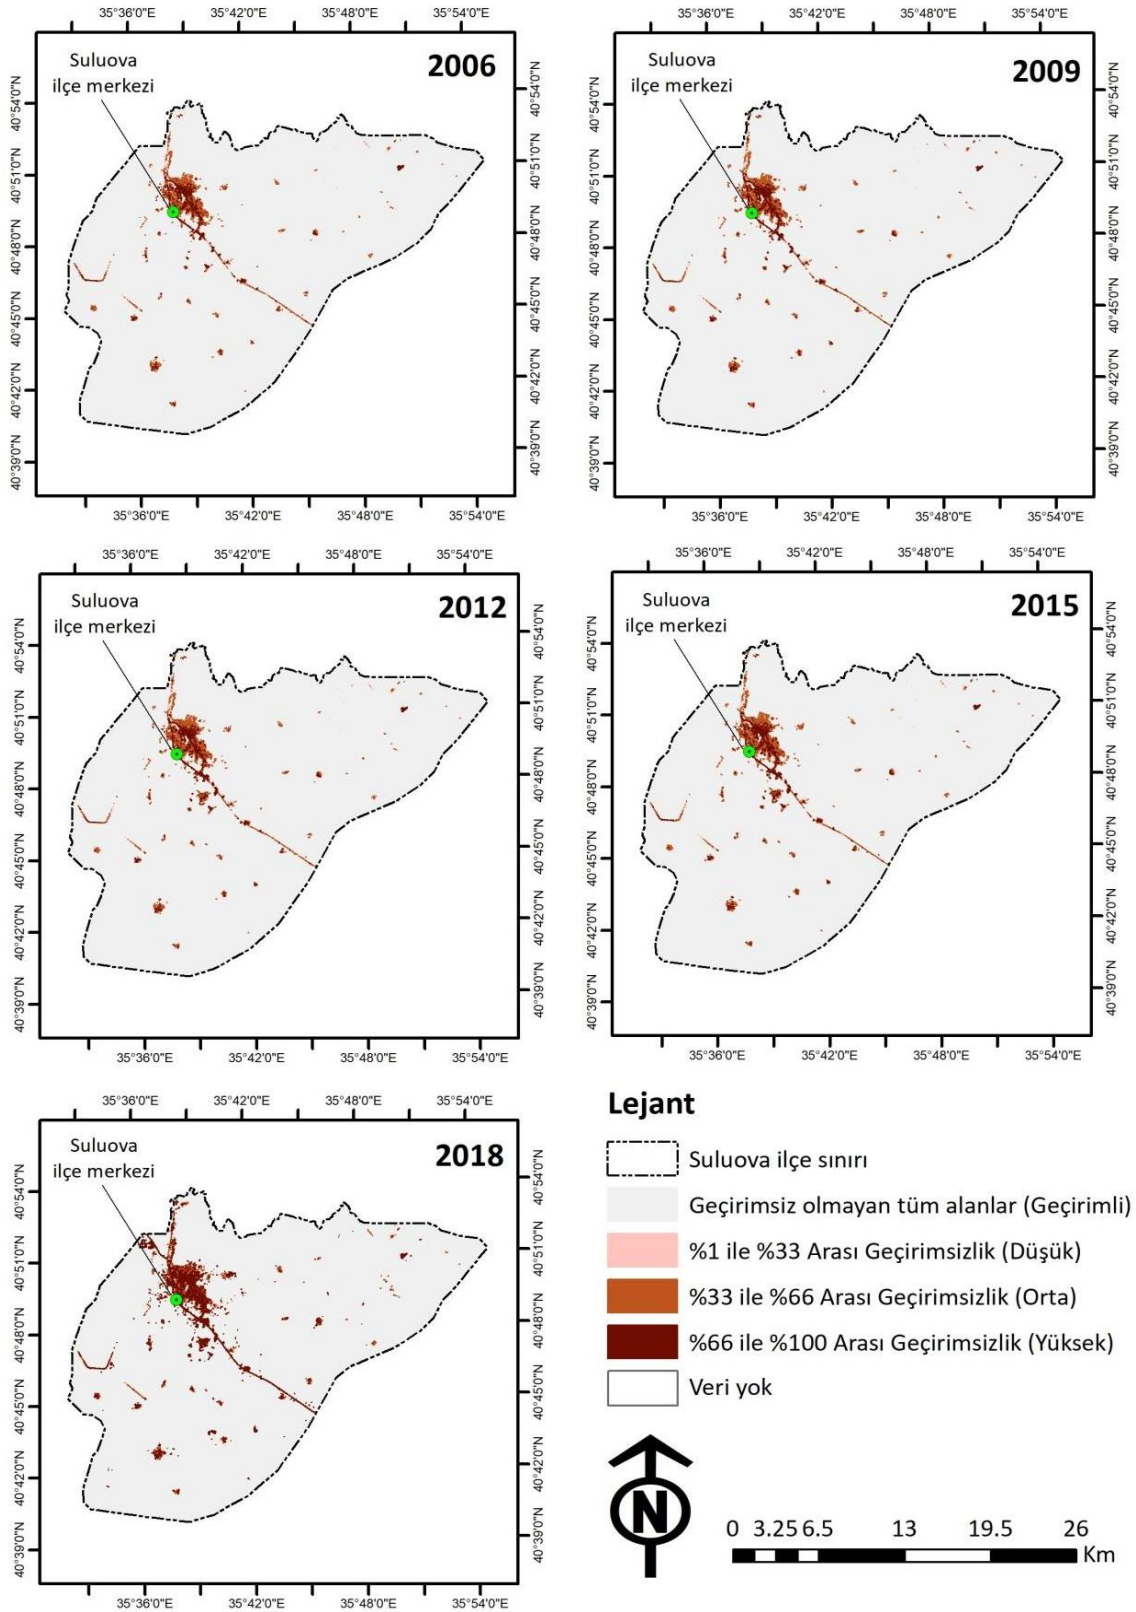
Şekil 6. Gümüşhacıköy ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Merzifon ilçesinde de Hamamözü ve Gümüşhacıköy ilçelerine benzer şekilde 12 yıllık süreçte geçirimsiz yüzeylerde 85,962.32 ha'dan 85,545.38 ha'a düşüş gözlenmiştir. Bununla birlikte, düşük dereceli geçirimsiz yüzeylerde %15 azalma, orta dereceli geçirimsiz yüzeylerde %13 azalma yaşandığı, yüksek dereceli geçirimsiz yüzeylerde ise %141 artış yaşandığı görülmüştür. Bu da bu alanların, yüksek geçirimsizliğe sahip kentsel yapılaşmış alanların yoğunluğuna olan dönüşümünü işaret etmektedir. Bu durum, Hamamözü ve Gümüşhacıköy ilçelerine benzer şekilde kentleşme faaliyetlerinin ve yoğun altyapı gelişiminin hızlandığını ve kentsel karakterdeki alanların arttığını ortaya koymaktadır (Şekil 7).



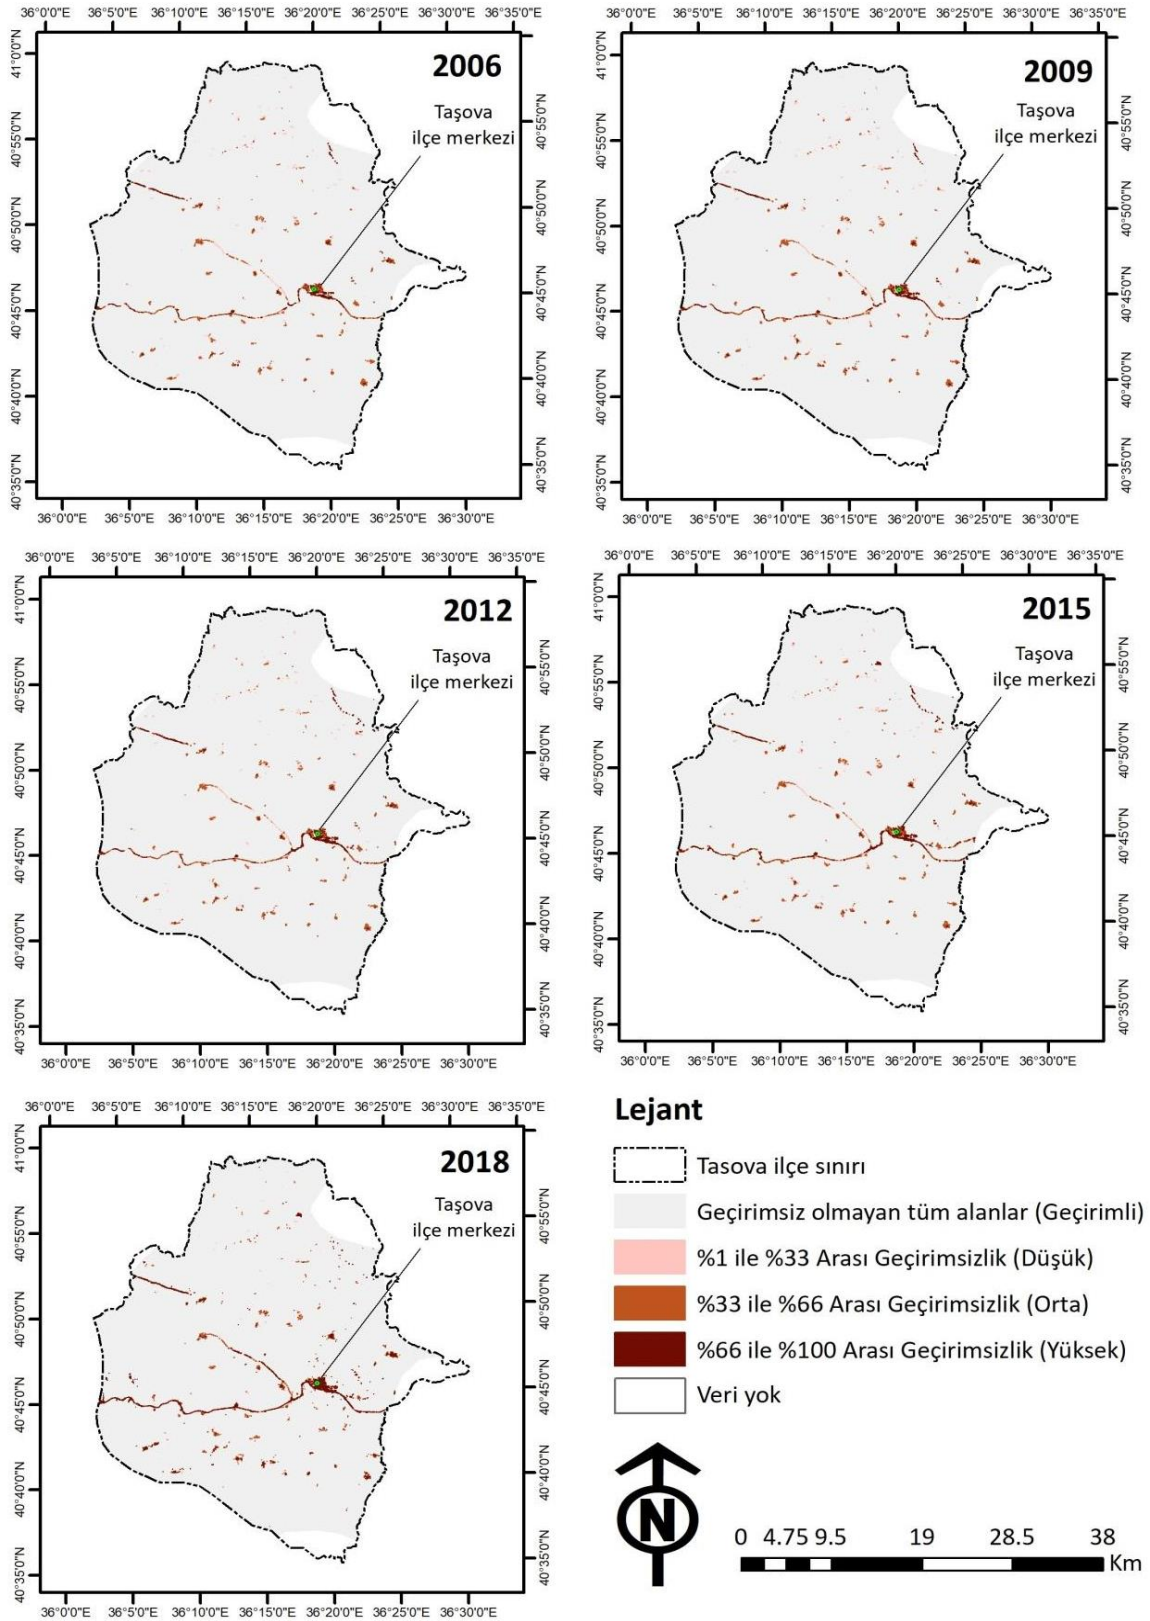
Şekil 7. Merzifon ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Suluova ilçesinde de geçirimli yüzeylerde 46,327.19 ha'dan 46,064.95 ha'a azalma yaşanmıştır. Düşük dereceli geçirimsiz yüzeylerde %25 azalma, orta dereceli geçirimsiz yüzeylerde %9 azalma, yüksek dereceli geçirimsiz yüzeylerde %201 artış yaşanmıştır. Bu durum, ilçedeki yüzey özelliklerindeki dönüşümünü işaret etmekte ve kentleşme ve sanayi faaliyetleri (Bilgin vd., 2017; Dede vd., 2017) gibi yapılaşma faaliyetlerinin arttığını göstermektedir (Şekil 8).



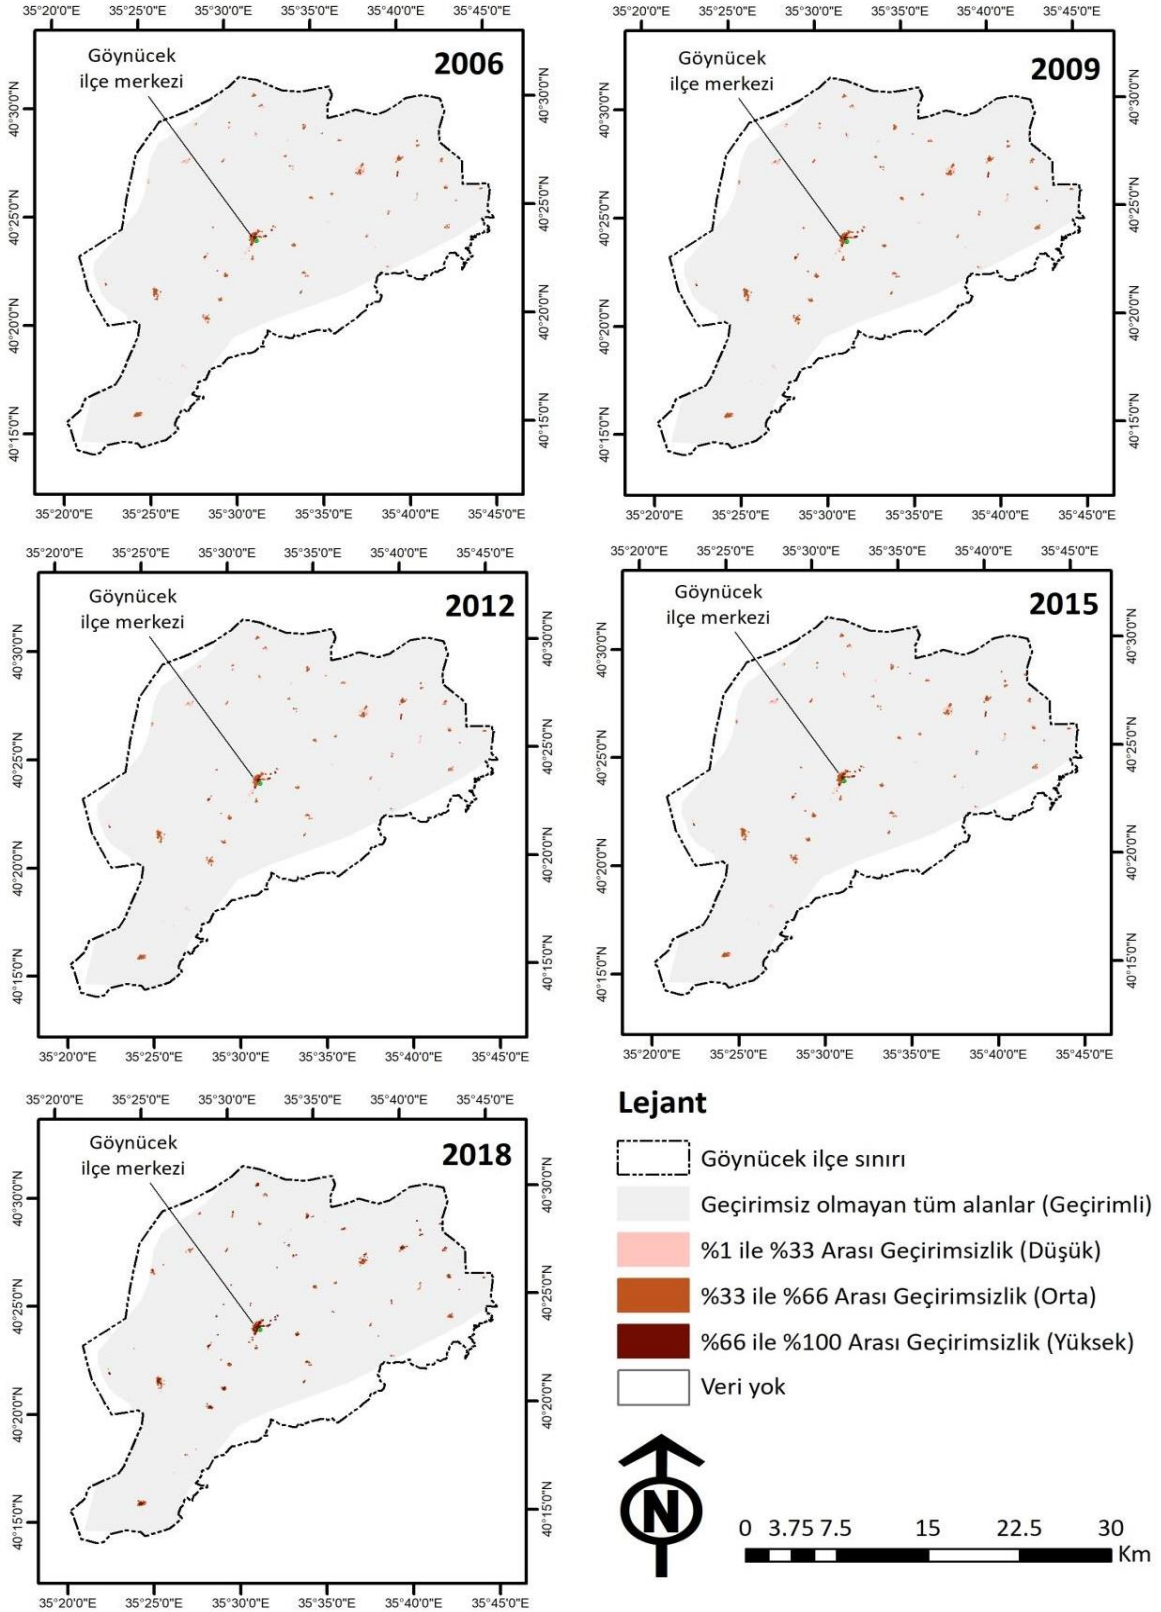
Şekil 8. Suluova ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Taşova ilçesinde ilgili yıllar arasında geçirimsiz yüzeyler 93,845.99 ha'dan 93,656.23 ha'a düşmüştür. Bununla birlikte düşük dereceli geçirimsiz yüzeylerde %6'lık azalma, yüksek dereceli geçirimsiz yüzeylerde %215 artış yaşanmıştır. Bu sonuç, düşük dereceli geçirimsiz yüzeylere sahip alanların bir kısmının kentsel gelişime geçerek yüksek dereceli geçirimsiz yüzeylere dönüşümünü ve ilçenin kentleşme eğiliminde olduğunu göstermektedir (Şekil 9).




Şekil 9. Taşova ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Göynücek ilçesinde ilgili yıllar arasında geçirimsiz yüzeyler 53,048.57 ha'dan 53,002.48 ha'a düşmüştür. Bununla birlikte, düşük dereceli geçirimsiz yüzeylerde %10 azalma, orta dereceli geçirimsiz yüzeylerde %16 artış, yüksek dereceli geçirimsiz yüzeylerde %369'luk artış yaşandığı görülmektedir. Bu durum, ilçede yüksek geçirimsiz yüzeylerin oluştuğunu göstermektedir (Şekil 10).



Şekil 10. Göynücek ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Merkez ilçesinde de ilgili yıllar arasında geçirimsiz yüzeyler 172,156.04 ha'dan 171,306.97 ha'a düşmüştür. Öte yandan, düşük dereceli geçirimsiz yüzeylerde %8 artış, orta dereceli geçirimsiz yüzeylerde %19 artış, yüksek dereceli geçirimsiz yüzeylerde ise %135'lik artış yaşandığı görülmektedir. Bu değişim, kent merkezindeki artan kentleşme hareketlerini ve altyapı gelişimini ortaya koymaktadır (Şekil 11).



Şekil 11. Merkez ilçesinin 2006 ile 2018 yılları arasındaki geçirimsizlik derecelerini gösteren haritalar

Özetle, Amasya il bütününde 2006 yılından 2018 yılına gelindiğinde bilhassa yüksek geçirimsizlik derecesine sahip alanların arttığı görülmektedir. İlçeler genel olarak değerlendirildiğinde ise, neredeyse tüm ilçelerde %0 geçirimsizlik derecesine sahip alanlarda çok ciddi ölçüde bir azalma olmaması doğal karaktere sahip alanların korunması açısından olumlu bir durum olarak değerlendirilmektedir. Ancak, birçok ilçede %1–%33 geçirimsizlik derecesine sahip alanlar düşüş trendine sahip olup, kentsel dönüşümler ve faaliyetler nedeniyle azalarak orta ve yüksek geçirimsizlik derecelerine kaymıştır. Geçirimsizlik derecesi %33-%66 arasında olan orta geçirimli yüzeylerde de belirli bir azalma olduğu, bu alanların yüksek geçirimsiz yüzeylere dönüştüğü anlaşılmaktadır. Geçirimsizlik derecesi %66-%100 arasında olan yüksek geçirimsiz yüzeylerde tüm ilçelerde bir artış görülürken yüzde değişim oranı açısından bakıldığında en yüksek sonucun Göynücek ve Hamamözü ilçelerinde olduğu görülmektedir. Özellikle 2015 ve 2018 yıllarında yüksek geçirimsiz yüzeylerin oranının tarımsal, nüfus ve yapısal faktörlerle ilişkili olarak tüm ilçelerde baskın hale geldiği görülmektedir. Öte yandan, 2018 yılı itibarıyla en fazla yüksek geçirimsizlik derecesine sahip alanlarla kaplı ilçenin 1,209.64 ha ile Merkez ilçe olduğu görülmüştür. Bunu 914.10 ha ile Merzifon ilçesi, 507.35 ha ile Suluova ilçesi izlemektedir. Bu sonuçlar, kentleşme faaliyetlerinin bu ilçelerde daha yoğun yaşandığını göstermektedir. İlçelerin yüzölçümlerine göre geçirimli ve geçirimsiz alanlar tümüyle değerlendirildiğinde ise, yüzölçümüne göre en yüksek geçirimsiz alanlara sahip ilçenin %2.32 toplam geçirimsiz alanlar ile Suluova olduğu görülmüştür. Bunu %2.06 ile Merzifon, %1.34 ile Merkez ilçe izlemektedir. Bu sonuçlar ve oranlar Amasya ilçelerinin esasında kırsal kimlikte alanlar olduğunu, ancak büyük ölçüde, mevcut geçirimsiz alanların geçirimsizlik yoğunluklarının yıllara bağlı olarak arttığını ortaya koymaktadır.

3.2. Regresyon Analizine İlişkin Bulgular

Tablo 4'te, Amasya ili ilçelerinde x ekseninde zaman/yıl ve y ekseninde ise geçirimsizlik derecesinin değişikliği gözlemi (y eksenini) sırasıyla bağımsız ve bağımlı değişkenler olarak ele alınmıştır. Bu tablodan, bağımsız ve bağımlı değişkenler arasındaki ilişkiden Amasya ili ilçeleri için doğrusal ve polinom denklemler hesaplanmıştır. Ayrıca, her ilçe için hesaplanan denklemlere karşılık gelen korelasyon katsayıları Tablo 5'te verilmiştir.

Tablo 5. Amasya ili ilçeleri için bağımsız ve bağımlı değişkenler arasındaki matematiksel ilişki ile elde edilen doğrusal ve polinom denklemler ile korelasyon katsayıları


İlçeler	Geçirimsizlik Derecesi (%)	Eşitlik	Korelasyon Katsayısı
Hamamözü	0%	$y = -0.6644x^3 + 4.6623x^2 - 10.618x + 20371$	0.9799
	1%-33%	$y = -0.8148x + 34.2928$	0.5653
	33%-66%	$y = 0.0825x^4 - 1.3479x^3 + 6.8092x^2 - 12.2299x + 57.4602$	1
	66%-100%	$y = 0.4279x^3 - 4.2818x^2 + 14.9970x - 21.4373x + 14.8414$	1
Gümüşhacıköy	0%	$y = -14.0383x^3 + 99.1341x^2 - 212.1729x + 59,438.1075$	0.9941
	1%-33%	$y = 1.1278x^4 - 11.9962x^3 + 44.8409x^2 - 67.4099x + 127.0071$	1
	33%-66%	$y = -0.0345x^3 + 0.9693x^2 - 2.3439x + 318.9788$	0.9998
	66%-100%	$y = 4.8527x^4 - 47.4584x^3 + 164.3516x^2 - 232.7388x + 202.2688$	1
Merzifon	0%	$y = -5.5379x^3 + 16.6861x^2 - 32.6763x + 85,987.7361$	0.9975
	1%-33%	$y = -5.5301x + 256.3603$	0.4393
	33%-66%	$y = -10.2435x + 817.1701$	0.2223
	66%-100%	$y = 20.3509x^4 - 210.0274x^3 + 766.6634x^2 - 1,130.3631x + 933.4541$	1
Suluova	0%	$y = -11.8279x^3 + 82.2172x^2 - 192.2010x + 46,453.3780$	0.9853
	1%-33%	$y = -7.8854x + 184.1149$	0.6004
	33%-66%	$y = -5.9046x + 533.7799$	0.2735
	66%-100%	$y = 14.8452x^4 - 152.9495x^3 + 553.2823x^2 - 809.4519x + 562.9502$	1

Tablo 5'in devamı

İlçeler	Geçirimsizlik Derecesi (%)	Eşitlik	Korelasyon Katsayısı
Taşova	0%	$y = -0.8990x^2 - 3.5688x + 1.8403x + 93,850.9340$	0.9923
	1%-33%	$y = -1.5624x + 152.4005$	0.4637
	33%-66%	$y = 3.3655x + 315.8379$	0.3216
	66%-100%	$y = 6.6743x^2 - 74.3159x^2 + 295.0407x^2 - 464.1534x + 317.7719$	1
Göynücek	0%	$y = -3.5373x^2 + 25.7281x^2 - 56.2331x + 53,083.1313$	0.9941
	1%-33%	$y = -1.4139x + 75.8181$	0.6322
	33%-66%	$y = 0.2167x^2 - 1.8464x^2 + 5.4391x^2 - 6.2000x + 75.4176$	1
	66%-100%	$y = 0.6378x^2 - 6.3693x^2 + 22.2578x^2 - 31.7296x + 19.3939$	1
Merkez	0%	$y = -36.5396x^2 + 233.4493x^2 - 480.2337x + 172,444.7124$	0.9980
	1%-33%	$y = 0.8958x^2 - 9.2321x^2 + 33.7070x^2 - 50.3257x + 293.5858$	1
	33%-66%	$y = 1.5130x^2 - 2.0253x^2 - 1.5526x + 702.9762$	0.9999
	66%-100%	$y = 15.0470x^2 - 147.0946x^2 + 525.4654x^2 - 766.7106x + 888.9997$	1

Tablo 5'te de görüldüğü üzere, bağımsız (yıl) ve bağımlı (geçirimsiz yüzey değişimi) değişkenler arasında genellikle çok yüksek korelasyon katsayısına sahip polinomal ilişkiler gözlemlenmiştir. Hiçbir ilçede iki değişken arasında hesaplanan korelasyon katsayısının 0.20'den az olmaması, değişkenler arasında en azından zayıf ilişki olduğunu göstermektedir. Söz konusu zayıf ilişki Merzifon, Suluova ve Taşova ilçeleri için hesaplanan orta dereceli geçirimsiz yüzeyler için olmuştur. Hamamözü, Merzifon ve Taşova ilçelerinde düşük dereceli geçirimsiz yüzeyler için hesaplanan korelasyon değerleri 0.40 ile 0.59 arasında olduğu için iki değişken arasında orta düzeyde ilişki olduğu söylenebilir. Suluova ve Göynücek ilçelerinde ise düşük dereceli geçirimsiz yüzeyler için hesaplanan korelasyon değerleri 0.60 ile 0.79 arasında olduğu için iki değişken arasında yüksek düzeyde ilişki olduğu yorumu yapılabilir. Hesaplanan 0.80 ve üzeri korelasyon değerine sahip olan formüllerde iki değişken arasında çok yüksek ilişki olduğu söylenebilir. İlçe bazında Merkez ve Gümüşhacıköy ilçelerinin tüm derecedeki geçirimsiz yüzeylerde iki değişken arasındaki ilişkiyi polinomsal olarak kurulabildiği ve hesaplanan korelasyon katsayı değerlerinin 1'e oldukça yakın olduğu görülmektedir.

Amasya ilindeki her bir ilçe için Tablo 5'te gösterilen denklemler kullanılarak ilçeler için 2030 yılında farklı derecelerdeki geçirimsiz yüzeylerin değer tahmini yapılmış ve elde edilen sonuçlar 2006 yılına göre artış miktarları hesaplanarak Şekil 12'de verilmiştir.



Şekil 12. 2006 ile 2030 yılları arasında geçirimsizlik derecesi değişimi (%)

Şekil 12'deki 2030 yılı Hamamözü ilçesi için yapılan tahmine göre geçirimli ve düşük dereceli geçirimsiz alanlarda azalma olduğu, orta ve yüksek dereceli geçirimsiz yüzeylerde ise yüksek seviyede artış olabileceği belirlenmiştir. Gümüşhacıköy ilçesi için yapılan tahminlerde geçirimli alanda en az %25 oranında azalma olurken diğer geçirimsiz yüzeylerde artış olduğu görülmektedir. Bu artışların en fazla düşük ve yüksek dereceli geçirimsiz yüzeylerde olabileceği belirlenmiştir. Merzifon ilçesi için yapılan 2030 yılına ait tahminlerine göre, yüksek dereceli geçirimsiz yüzeylerin alanında yaklaşık %100'lük bir artış olurken, diğer alanlarda azalma olduğu görülmektedir. Benzer durum Suluova ilçesi için de söylenebilir. Ancak bu ilçe için düşük dereceli geçirimsiz yüzeydeki azalışın oldukça fazla olabileceği hesaplanmıştır. Taşova ilçesi için yapılan tahminde geçirimli yüzey ve düşük dereceli geçirimsiz yüzeyde azalış olurken, orta ve yüksek dereceli geçirimsiz yüzeyde artış görülmektedir. Benzer durum Göynücek ilçesi için de söylenebilir. Ancak bu ilçede orta dereceli geçirimsiz yüzey artışı oldukça fazladır. Yapılan tahminlerde Merkez ilçesini diğer tüm ilçelerden ayıran en önemli sonuç, geçirimli yüzeylerin alanındaki azalma değil, geriye kalan tüm farklı seviyedeki geçirimsiz yüzey alanlarındaki yüksek artış miktarıdır.

4. Sonuç ve Tartışma

Hızlı kentleşme sürecinin devam ettiği ve mevcut yapılaşmış alanların değerlendirilmesinin giderek daha da önemli bir hale geldiği günümüz koşullarında, kentlerin geleceğine yönelik planlama çalışmaları oldukça önem kazanmıştır. Bu doğrultuda çalışmada, Amasya il bütününde 2006, 2009, 2012, 2015 ve 2018 yıllarına ait Copernicus Yüksek Çözünürlüklü Katman Geçirimsizlik Yoğunluğu (HRL IMD) verileri kullanılarak geçirimsizlik dereceleri sınıflandırılmış, bu dereceler haritalanmış, yıllara göre kentsel arazi değişim oranları hesaplanmış ve 2030 yılı için geçirimsizlik derecelerine yönelik tahminler üretilmiştir.

Geçirimsiz yüzey alanlarının zaman içindeki değişimi, kentsel büyüme ve arazi kullanımı dönüşümleri açısından doğal bir süreç olarak değerlendirilebilir. Ancak, bu artışın belirli bir eşik değeri aşması durumunda ekolojik denge, hidrolojik döngü ve biyolojik çeşitlilik üzerinde olumsuz etkiler yaratabileceği bilinmektedir. Literatürde, geçirimsiz alan artışının çevresel sürdürülebilirliği tehdit edebileceği belirli eşik değerleri üzerine çalışmalar (UZF Center for Environmental Research, 2004; Bayramoğlu vd., 2019; Doygun & Kısakürek, 2023) bulunmakla birlikte, bu eşik değerler bölgesel bağlam, ekosistem hassasiyeti ve arazi kullanım planlaması gibi değişkenlere bağlı olarak farklılık göstermektedir. UZF Center for Environmental Research (2004), Bayramoğlu vd. (2019), Doygun ve Kısakürek (2023)'in yapmış oldukları çalışmalara göre; yeşil alanların geçirgenlik durumlarının değerlendirilmesinde sert zeminle kaplı alanların bütün içerisindeki oranları %20'den büyük ise, bu parkın geçirgenlik düzeyinin ekolojik bakımdan "uygun olmadığı" sonucuna varılmıştır. %10-20 arasındaki sert zemin oranları, yoğun olarak kullanılan yeşil alanlar için ekolojik bakımdan "kabul edilebilir" düzey olarak değerlendirilirken, %5-10 oranı yeşil alanların geneli için "iyi", %5'ten küçük oranlar için ise "ideal" değerlendirmesi yapılmıştır.

Amasya ilçelerinden yoğunlukla kırsal karaktere sahip olan Hamamözü, Gümüşhacıköy, Taşova, Göynücek ve Suluova ilçelerinde 2006-2018 yılları arasında nüfus kaybının yaşandığı görülmüştür. Bu durum, söz konusu ilçelerde çeşitli faktörlerin etkisi ile nüfusun göç hareketi gerçekleştirdiğini ortaya koymaktadır. Bu ilçelerin aksine Merkez ve Merzifon ilçelerinde ise ilgili yıllar arasında nüfus artışı yaşanmıştır. Bu durumun ortaya çıkmasında, bu ilçelerdeki kentleşme faaliyetlerinin daha yoğun olması ve ekonomik imkânlarının fazlalığı vb. pek çok sebebin etkili olmuş olabileceği söylenebilir. Buna karşılık ilçelerde özellikle 2015 sonrasında özellikle yüksek dereceli geçirimsiz yüzeylerde artış gözlemlendiği görülmektedir. Merzifon ve Suluova ilçelerinde görülen artışın sebebi sanayi alanlarının giderek büyümesi ve konut alanı talebinin artmasıdır (Bilgin vd., 2017; Dede vd., 2017). Daha kırsal özelliklere sahip Gümüşhacıköy, Hamamözü ve Göynücek ilçelerinde de ilçe insanı tarım ve hayvancılıkla geçimini sağlamaktadır. Bu ilçelerde 2006'dan 2018 yılına nüfus artışı olmamasına rağmen tarım alanı olarak kullanılan yerlerin bir kısmının miras nedeni ile küçülmesi, tarım faaliyetlerinden elde edilen gelirin azalması vb. nedenlerden dolayı tarım alanları satışa çıkartılarak inşaat firmalarının eline geçmekte, dolayısıyla tarım alanları hızla konut alanlarına dönüşmektedir (T.C. Amasya Valiliği Çevre ve Şehircilik İl Müdürlüğü, 2013; Şenol, 2014; T.C. Amasya Valiliği Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü, 2024). Yapılaşma arttığı için de geçirimsiz yüzeylerin oranında artış olmaktadır. Nitekim, ilçeler arasındaki nüfus artış ve azalma oranları ekonomik ve sosyal altyapı farklılıklarını yansıtmakta olup, Merkez ve Merzifon ilçelerindeki artış diğer ilçelerden aldığı göç faaliyetleri (Eren, 2020) ile desteklenmektedir. Bu durum, Kalkınma Ajansları Genel Müdürlüğü (2019) tarafından yayımlanan "Nüfus Yoğunluğu ve Kentsel İşlevler ile Türkiye'de İlçelerin Kentleşme Düzeyinin Ölçülmesi" başlıklı raporunda belirtilen Türkiye'de ilçe düzeyinde nüfus yoğunluğuna bağlı olarak hesaplanan kentleşme oranı tahminleriyle benzerlik göstermektedir. Benzer şekilde, çalışmada Amasya il bütününe nüfus yoğunluğuna bağlı olarak hesaplanan kentleşme oranının %29-%53 aralığında olduğu ve orta derecede yoğunluklu bir kent olduğu saptanmıştır. Bununla birlikte, Sarı vd. (2020)'ne göre kentin hem nüfus yoğunluğu hem de kentsel işlev düzeyinin düşük olduğu, Eren (2020)'e göre kent nüfusunun Türkiye nüfusunun %0.78'ini oluşturduğu, Dede vd. (2017)'ne göre kentin ekonomisinde tarımın ilk sırada yer aldığı, Kızılaslan ve Arslan (2022)'a göre kentin temel geçim kaynağı tarımın terk edilip kentleşmeye bağlı kırsal göç faaliyetlerinin görüldüğü sonucuna varılmıştır.

Amasya ilinin 2006 ile 2018 yıllarındaki toplam nüfusları ile kentli nüfus sayıları karşılaştırıldığında; 2006 yılında kentli nüfus toplam nüfusun %61.25'i iken, 2018 yılında bu oran %71'e ulaşmıştır. Kırsal nüfus oranı da %38.73'ten %29'a düşmüştür (Türkiye İstatistik Kurumu, 2024b). Bu kentleşme süreci, kent içerisinde boş/kullanılmayan alanlarda yapılaşmanın artmasına ve bağ/bahçe/tarım alanlarının yerleşim, sanayi ve ticaret alanlarına dönüştürülmesine neden olmuştur (Amasya Valiliği Çevre ve Şehircilik İl Müdürlüğü, 2013). Bu süreç, hem kent merkezinde hem de ilçelerde yeşil alan miktarında yani geçirimli yüzeylerde azalmalara, geçirimsiz yüzeylerde artışa neden olmuştur.

2006 ile 2018 yılları arasındaki durum ilçeler bazında değerlendirildiğinde ve Şekil 5-11 incelendiğinde; geçirimsiz alan yoğunluğunun ilçe merkezlerinde toplandığı görülebilmektedir. Hamamözü ilçesinin nüfusu %24 oranında azalma ile 5,264'ten 3,955'e düşmüştür. Bu demografik gerileme, kırsal alanların boşalması ve ekonomik faaliyetlerin zayıflaması (Dede vd. 2017) ile ilişkilendirilebilir. Aynı süreç içerisinde geçirimli yüzeylerde önemli ölçüde bir değişiklik gözlenmezken arazi kullanımında dönüşümler (düşük ve orta dereceli geçirimsiz yüzeylerde azalma, yüksek dereceli geçirimsiz yüzeylerde artış) meydana geldiği görülmektedir. Bu da, ilçe genelinde nüfusun azalmasına rağmen kentsel nitelikli alanlarda birtakım faaliyetlerin arttığını göstermektedir. Kentsel gelişmenin artmasının demografik ve yerel ekonomik yapının değişimiyle doğrudan bağlantılı bir süreç olduğu düşünülmektedir. Öte yandan, kentsel gelişmelere rağmen ilçenin halihazır haritaları ile imar planı bulunmamaktadır (Dede vd., 2017; Hamamözü Belediyesi, 2024). 2030 yılına yönelik tahminlerde ise ilçede düşük dereceli geçirimsiz yüzeylerin azalacağı, geçirimsiz yüzeylere göre orta ve yüksek dereceli geçirimsiz yüzeylerde ise belirgin bir artış yaşanacağı öngörülmektedir.

Gümüşhacıköy ilçesi nüfusu %7.4 oranında azalarak 25,632'den 23,734'e gerilemiştir. Bu durum, ilçenin ekonomik cazibesinin azalması veya genç nüfusun dış göç eğiliminde olması (Eren, 2020) ile ilişkilendirilmiştir. Aynı dönemde, ilçedeki doğal yani geçirimli yüzeylerde azalış meydana gelirken, arazi kullanımındaki değişimlerin (düşük, orta ve yüksek dereceli geçirimsiz yüzeylerde artış) meydana geldiği görülmektedir. Bu sonuçlar, geçirimsiz yüzeylerde artış yaşanarak ilçede kentleşme süreçleri ile altyapı gelişiminin ivme kazandığını ortaya koymaktadır. Hamamözü ilçesine benzer şekilde Gümüşhacıköy ilçesinin de imar planı bulunmamaktadır (Dede vd., 2017; Gümüşhacıköy Belediyesi, 2024). 2030 yılı için ilçedeki geçirimli yüzeylerin en az %25 oranında azalacağı, buna karşılık tüm geçirimsiz yüzey türlerinde artışların gerçekleşeceği öngörülmektedir.

Merzifon ilçesi nüfusu %4.1 oranında artış göstererek 69,093'ten 71,916'ya yükselmiştir. Bu nüfus artışı, ilçenin eğitim, sanayi ve ticaret potansiyelindeki gelişmenin bir göstergesi olarak değerlendirilmektedir (Bilgin vd., 2017). Söz konusu dönemde, Merzifon'da da geçirimli yüzeylerde azalış yaşandığı gözlenmiştir. Düşük ve orta dereceli geçirimsizlik düzeyindeki alanlar ise kentsel yoğunluk içeren alanlara dönüşmüş ve yüksek dereceli geçirimsiz yüzeyler artış göstermiştir. Bu durum, ilçede kentleşme faaliyetlerinin ve yoğun altyapı gelişiminin hızlandığını ortaya koymaktadır. Arazi kullanımındaki bu dönüşüm, nüfus artışı ile uyumlu bir şekilde ilçenin ekonomik ve sosyal yapısındaki değişimle de ilişkilendirilmektedir. Öte yandan ilçenin imar planı bulunmaktadır (T.C. Amasya Valiliği, 2023; Merzifon Belediyesi, 2024). Çalışma kapsamında gerçekleştirilen 2030 yılına ilişkin öngörüler, yüksek dereceli geçirimsiz yüzeylerin yaklaşık %100 oranında artacağını, buna karşılık diğer yüzey türlerinde de azalmaların yaşanacağını ortaya koymaktadır.

Suluova ilçesi nüfusu %1.7 oranında azalarak 47,428'den 46,608'e gerilemiştir. Bu azalma, diğer ilçelere kıyasla sınırlı düzeyde kalmış olup, ilçede ekonomik stabilitenin devam ettiğini (Bilgin vd., 2017; Dede vd., 2017) göstermektedir. İlçede geçirimli yüzeylerde azalma gözlenmiştir. Buna karşılık, düşük dereceli geçirimsiz yüzeylerde %25, orta dereceli geçirimsiz yüzeylerde %9 oranında azalma, yüksek dereceli geçirimsiz yüzeylerde ise %201 oranında artış yaşanmıştır. Bu durum, ilçede kentleşme ve sanayi gibi yapılaşmaya yönelik faaliyetlerin arttığını ve arazi kullanımında dönüşümlerin meydana geldiğini ortaya koymaktadır. 2030 yılına ilişkin tahminler de benzer bir eğilime işaret etmekte, ancak düşük dereceli geçirimsiz yüzeylerdeki azalmanın daha belirgin bir düzeyde olacağı öngörülmektedir. Tahminler, ilçede sanayi ve kentsel faaliyetlerin artmaya devam edeceğini ve bu süreçlerin arazi üzerindeki etkilerinin daha da yoğunlaşacağını göstermektedir.

Taşova ilçesi nüfusu %10.4 oranında azalarak 35,186'dan 31,508'e düşmüştür. Bu nüfus kaybı, kırsal göç ve genç nüfusun başka bölgelere taşınması (Eren, 2020) ile ilişkilendirilmektedir. Aynı dönemde geçirimli yüzeyler ile orta dereceli geçirimsiz yüzeylerde azalma gözlenmiştir. Düşük dereceli geçirimsiz yüzeylerde ise %6 oranında azalma görülmektedir. Bu durum, bu alanların kentsel gelişim alanlarına dönüşerek yüksek geçirimsiz yüzeylerde %215 oranında bir artışa neden olduğunu göstermektedir. Söz konusu artış, ilçede kentleşme eğiliminin ve kentsel altyapı faaliyetlerinin yoğunlaştığını işaret etmekte olup bu dönüşüm, nüfus kaybı olmasına rağmen, arazi kullanımında kentleşmeye yönelik dinamiklerin güçlendiğini ortaya koymaktadır. 2030 yılına ilişkin öngörüler de ilçede geçirimli yüzeyler ile düşük dereceli geçirimsiz yüzeylerde azalma yaşanacağını, buna karşılık orta ve yüksek dereceli geçirimsiz yüzeylerde artışların meydana geleceğini ortaya koymaktadır.

Göynücek ilçesi nüfusu %20.3 oranında azalarak 13,425'ten 10,703'e düşmüştür. Bu nüfus kaybı, kırsal göç, ekonomik yetersizlikler, tarım alanlarının işlev kaybı (Çağlar vd., 2017; Eren, 2020) gibi faktörlerle ilişkilendirilmektedir. Aynı dönemde, ilçedeki doğal yani geçirimli yüzeyler ile düşük dereceli geçirimsiz yüzeylerde azalma, orta dereceli geçirimsiz yüzeylerde %16 oranında ve yüksek geçirimsiz yüzeylerde ise %369 oranında olmak üzere bir artış görülmüştür.

Bu durum, ilçede geçirimsiz yüzeylerin arttığını, dolayısıyla kentleşme ve altyapı yoğunluğunun yükseldiğini göstermektedir. Arazideki bu dönüşüm, ilçenin demografik gerilemesine rağmen yapılaşmaya yönelik faaliyetlerin ve kentleşmenin, bölgedeki arazi kullanımını şekillendirdiğini ortaya koymaktadır. Benzer bir süreç 2030 yılına ilişkin yapılan tahminlerde de öngörülmektedir.

Merkez ilçesi nüfusu %12.4 oranında artarak 132,646'dan 149,084'e yükselmiştir. Bu nüfus artışı, ilçenin kentsel çekim gücünün artması, ekonomik ve sosyal olanakların daha fazla bireyi bölgeye çekmesi (Eren, 2020) ile ilişkili olup; kentleşme süreçleri ve göç dinamiklerinin etkisini de yansıtmaktadır. İlgili yıllar arasında ilçedeki geçirimsiz yüzeylerde azalma yaşandığı görülmüştür. Bununla birlikte düşük dereceli geçirimsiz yüzeylerde %8, orta dereceli geçirimsiz yüzeylerde %19, yüksek dereceli geçirimsiz yüzeylerde %135 oranında bir artış gerçekleşmiştir. Bu değişim, kent merkezinde hızlı kentleşme süreçlerinin ve altyapı yatırımlarının yoğun bir şekilde gerçekleştiğini (Bilgin vd., 2017; Özdemir & Özkaynak, 2023); Kurt (2013), Kurdoğlu vd. (2014), Kurdoğlu vd. (2016), Kurdoğlu ve Kurt (2017), Kurdoğlu ve Kurt Konakoğlu (2018)'in çalışmalarında belirlemiş olduğu yeşil alanların ise sert zemin yüzeylere dönüştüğünü ortaya koymaktadır. İlçenin arazi kullanımındaki bu dönüşümün, kentsel büyüme ve altyapı gelişimi ile uyumlu bir şekilde olduğu görülmektedir (Ergen, 2017). 2030 yılı için tüm farklı derecedeki geçirimsiz yüzeylerde yüksek artış miktarının görüleceği tahmin edilmektedir.

Doğrusal ve polinom regresyon modelleri kullanılarak Amasya ilinin her bir ilçesi için 2006 yılından 2030 yılına yönelik yapılan tahminler genel olarak değerlendirildiğinde, mevcut kentsel büyümenin devam edeceği, yerel dinamiklerin ekonomik ve fiziksel yapısı üzerindeki etkilerinin daha belirgin hale gelebileceği, ancak arazi kullanımındaki geçişlerin farklı derecedeki geçirimsiz yüzeyler arasında yeniden dağılım gösterebileceği öngörülmektedir. Ayrıca, nüfus azalışının sürmesi beklenirken, kentsel alanlardaki yoğunlaşmanın dolayısıyla geçirimsiz yüzeylerin artacağı tahmin edilmektedir. Öte yandan, geçirimsiz yüzeylerin artışıyla kentlerin ekolojik açıdan olumsuz olarak etkilenmesi kaçınılmazdır. Nitekim bu durum, iklim değişikliği azaltım stratejisi ve eylem planı (İklim Değişikliği Başkanlığı, 2023a) ile iklim değişikliğine uyum stratejisi ve eylem planı (İklim Değişikliği Başkanlığı, 2023a)'n da kent in şiddetli yağış riski ile tehlikeli sıcak hava dalgasına maruz kalacağı şeklinde değerlendirilmiştir.

5. Öneriler

Çalışmada elde edilen bulgular dâhilinde, arazilerin geçirimsizlik oranlarında gözlemlenen değişimlerin altında yatan doğal ve insan kaynaklı faktörlerin detaylı bir şekilde incelenmesi, yüksek ve düşük geçirimsizlik oranlarına sahip alanların sürdürülebilir yönetimini sağlamak amacıyla uygun stratejilerin geliştirilerek alanların bölgesel özelliklerine uygun arazi kullanım politikalarının uygulanması önerilmektedir. Bununla birlikte, geçirimsiz yüzeylerdeki değişimin düzenli olarak izlenmesi ekolojik sürdürülebilirlik açısından oldukça önem taşımaktadır. Bu nedenle, geçirimsiz yüzeylerde görülen artışın ekosistem hizmetleri üzerindeki etkilerinin detaylı bir şekilde değerlendirilmesi gerekmektedir. Yüksek geçirimsiz yüzeylerin artması hususu yerel farklılıklar bağlamında ele alındığında, bölgesel farklar ve yüzeylerin geçirimsizlik durumları üzerindeki antropojenik etkilerin incelenmesi gerektiğini ortaya koymakta olup, bölgesel ve yerel ölçekte detaylı analiz ve politika geliştirme ihtiyacını vurgulamaktadır.

Çeşitli toplumsal ihtiyaçlar nedeniyle kentlere müdahalede bulunulacaksa, kentin fiziksel, toplumsal ve tarihi vb. tüm dinamikleri dikkate alınarak değerlendirmeler yapılmalı, tespit edilen sorunları çözüme kavuşturmak adına önerilerin ekolojik planlama ilkeleri çerçevesinde geliştirilmesi gerekmektedir. Ayrıca, kente dair eksik olan mevcut duruma ilişkin ve geleceğe dair gelişime yön verecek tüm planların kapsamlı bir şekilde ele alınarak, detaylı irdelemeler sonucunda hazırlanması önerilmektedir.

Bu çalışmada kullanılan veri seti ile kentteki geçirimsizlik dereceleri sınıflandırılmış, elde edilen alansal sonuçlar nüfus verileri ve kentleşme faaliyetlerine bağlı olarak irdelenmiştir. Bu bağlamda Amasya ili özelinde elde edilen sonuçlar, sürdürülebilir arazi yönetimi ve yerel düzeyde uygulanabilir politikaların geliştirilmesine yönelik önemli bir kaynak niteliği taşımakta olup, sonuçların kent düzeyinde hazırlanacak stratejik planlar için de önemli bir veri oluşturacağı düşünülmektedir. Gelecek çalışmalarında, kentsel arazi kullanım durumlarını ortaya koyan arazi kullanım durumu haritaları, uzaktan algılama yöntemleri ile geliştirilmiş kent indislerinin uygulanması ile kentsel alan kullanım durumlarının ortaya konulması vb. farklı yöntemler kullanılarak sonuçların bu veri seti sonuçlarıyla birlikte değerlendirilmesi sağlanabilir.

Kaynaklar

- Akay, A. (2019). *İklim değişikliğinin neden olduğu afetlerin etkileri*. <https://www.iklimin.org/moduller/afetmodulu.pdf>
- Arda, G. (2020). Landsat uydu görüntüleri kullanılarak nesne tabanlı sınıflandırma yöntemi ile alan kullanım/arazi örtüsü değişiminin değerlendirilmesi: Muğla-Ula örneği. *ArtGRID-Journal of Architecture Engineering and Fine Arts*, 2(1), 49–61.

- Armour, T., Armour, S., Hargrave, J., & Revell, T. (2014). *Cities alive: Rethinking green infrastructure*. ARUP. <https://www.arup.com/insights/cities-alive-rethinking-green-infrastructure/>
- Ataöv, A., & Osmay, S. (2007). Türkiye’de kentsel dönüşüme yöntemsel bir yaklaşım. *ODTÜ Mimarlık Fakültesi Dergisi*, 24(2), 57–82.
- Bayraç, H. N. (2010). Enerji kullanımının küresel ısınmaya etkisi ve önleyici politikalar. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 11(2), 229–259.
- Bayramoğlu, E., Yeniçirak, P. Ö., & Kurdoğlu, B. Ç. (2019). Kentsel açık alanların geçirimsizlik açısından incelenmesi: Trabzon kenti örneği. *International Journal of Social and Humanities Sciences Research (JSHSR)*, 45(6), 3868–3873.
- Berry, B. J. (2008). Urbanization. In J. M. Marzluff, E. Shulenberg, W. Endlicher, M. Alberti, G. Bradley, C. Ryan, U. Simon, & C. ZumBrunnen (Eds.), *Urban ecology: An international perspective on the interaction between humans and nature* (pp. 25–48). Springer.
- Bilgin, M. B., Biçer, E., & Kabacı, M. A. (2017). *Amasya ili sanayi sektörel eylem planı (2018-2023)*. Orta Karadeniz Kalkınma Ajansı. <https://oka.gov.tr/assets/upload/dosyalar/49amasya-cevre-ve-altyapi-eylem-planı---revize-sayfalar-silindi.pdf>
- Carter, J. G., Handley, J., Butlin, T., & Gill, S. (2018). Adapting cities to climate change—exploring the flood risk management role of green infrastructure landscapes. *Journal of Environmental Planning and Management*, 61(9), 1535–1552. <https://doi.org/10.1080/09640568.2017.1355777>
- Chapman, S., Watson, J. E. M., Salazar, A., Thatcher, M., & McAlpine, C. A. (2017). The impact of urbanization and climate change on urban temperatures: A systematic review. *Landscape Ecology*, 32, 1921–1935.
- Çağlar, Ö., Kılınc, G., Koparan, E., Yivli, A., & Topsakal, H. (2017). *Amasya ili tarım ve kırsal kalkınma eylem planı (2018-2023)*. Orta Karadeniz Kalkınma Ajansı. https://oka.gov.tr/assets/upload/dosyalar/52amasya-tarim-ve-kirsal-kalkinma-eylem-planı_v2.pdf
- Çalhan, E., & Özelcan, E. (2022). Şehirleşmenin yer yüzeyi sıcaklıklarına etkisinin incelenmesi: Denizli ili kent merkezi örneği. *Journal of Research in Atmospheric Science*, 4(1), 20–30. <https://doi.org/10.29228/resatmsci.64012>
- Dai, Z., Guldmann, J. M., & Hu, Y. (2018). Spatial regression models of park and land-use impacts on the urban heat island in central Beijing. *Science of the Total Environment*, 626, 1136–1147.
- Dale, V. H., Joyce, L. A., McNulty, S., & Neilson, R. P. (2000). The interplay between climate change, forests, and disturbances. *Science of the Total Environment*, 262(3), 201–204. [https://doi.org/10.1016/S0048-9697\(00\)00522-2](https://doi.org/10.1016/S0048-9697(00)00522-2)
- Das, M., & Das, A. (2019). Estimation of ecosystem services (EESs) loss due to transformation of local climatic zones (LCZs) in Sriniketan-Santiniketan planning area (SSPA) West Bengal, India. *Sustainable Cities and Society*, 47, Article 101474. <https://doi.org/10.1016/j.scs.2019.101474>
- Das, M., & Das, A. (2020). Assessing the relationship between local climatic zones (LCZs) and land surface temperature (LST) - A case study of Sriniketan-Santiniketan planning area (SSPA), West Bengal, India. *Urban Climate*, 32, Article 100591. <https://doi.org/10.1016/j.uclim.2020.100591>
- Davis, K. (1955). The origin and growth of urbanization in the world. *American Journal of Sociology*, 60(5), 429–437. <https://doi.org/10.1086/221602>
- Dede, O. M., Altanlar, A., Özcan, C., & Çorsuz, N. (2017). *Amasya ili çevre ve altyapı sektörel eylem planı (2018-2023)*. Orta Karadeniz Kalkınma Ajansı. <https://oka.gov.tr/assets/upload/dosyalar/amasya-cevre-ve-altyapi-eylem-planı.pdf>
- Dong, W., Liu, Z., Zhang, L., Tang, Q., Liao, H., & Li, X. (2014). Assessing heat health risk for sustainability in Beijing’s urban heat island. *Sustainability*, 6(10), 7334–7357. <https://doi.org/10.3390/su6107334>
- Doğun, N., & Kısakürek, Ş. (2013). Kahramanmaraş’da bazı kent parklarının geçirimsiz zemin yeterliği bakımından incelenmesi. *İnönü Üniversitesi Sanat ve Tasarım Dergisi*, 3(7), 23–29.
- Drašković, B. J. (2021). Urban expansion of the largest cities in Bosnia and Herzegovina over the period 2000-2018. *Geographica Pannonica*, 25(4), 276–288. <https://doi.org/10.5937/gp25-32535>
- Dünya Bankası. (2022). *Urban population (% of total population)*. World Bank Data. <https://data.worldbank.org/indicator/SP.URB.TOTL.IN.ZS?contextual=default>
- Eren, Ş. (2020). Türkiye’de, Amasya iline kayıtlı nüfusun coğrafi dağılışı. *Amasya Üniversitesi Sosyal Bilimler Dergisi (ASOBİD)*, 7, 161–210.
- Ergen, Y. B. (2017). Amasya’s urbanization problems. *Trakya University Journal of Engineering Sciences*, 18(2), 113–119.
- Ersoy Tonyaloğlu, E. (2019). Kentleşmenin kentsel termal çevre üzerindeki etkisinin değerlendirilmesi, Efeler ve İncirliova (Aydın) örneği. *Türkiye Peyzaj Araştırmaları Dergisi*, 2(1), 1–13.
- Ersöz, N. D., Ersoy Mirici, M., & Sayan Atanur, G. (2022). Geçmişten günümüze yeşil altyapı ve gelecek için öngörüler. In G. Bayrak (Ed.), *Yeşil Altyapı* (pp. 39-62). *IKSAD Yayınevi*.
- European Union Copernicus Land Monitoring Service. (2018). *Copernicus Land Monitoring Service - High Resolution Layer Imperviousness Product Specifications*. European Environment Agency (EEA). <https://land.copernicus.eu/en/technical-library/hrl-imperviousness-technical-document-prod-2015/@@download/file>

- European Union Copernicus Land Monitoring Service. (2024). *User Manual - Copernicus Land Monitoring Service High Resolution Land Cover Characteristics Lot1*. European Environment Agency (EEA). <https://land.copernicus.eu/en/technical-library/hrl-imperviousness-2018-user-manual/@@download/file>
- Foster, J., Lowe, A., & Winkelmann, S. (2011). *The value of green infrastructure for urban climate adaptation*. Center for Clean Air Policy. https://www.ca-ilg.org/sites/main/files/file-attachments/the-value-of-green-infrastructure-for-urban-climate-adaptation_ccap-february-2011.pdf?1376354679
- Gago, E. J., Roldan, J., Pacheco-Torres, R., & Ordóñez, J. (2013). The city and urban heat islands: A review of strategies to mitigate adverse effects. *Renewable and Sustainable Energy Reviews*, 25, 749–758.
- Gawuc, L., & Struzewska, J. (2016). Impact of MODIS quality control on temporally aggregated urban surface temperature and long-term surface urban heat island intensity. *Remote Sensing*, 8(5), Article 374. <https://doi.org/10.3390/rs8050374>
- Gümüşhacıköy Belediyesi. (2024). Duyurular. 11 Aralık 2024'te <https://www.gumushacikoy.bel.tr/> adresinden alındı.
- Hamamözü Belediyesi. (2024). *İmar İşleri*. 11 Aralık 2024'te <https://hamamozu.bel.tr/hizmet/imar-isleri.html> adresinden alındı.
- Howard, L. (1833). *The climate of London, deduced from meteorological observations, made in the metropolis and at various places around it*. Harvey and Darton.
- İklim Değişikliği Başkanlığı. (2023a). *İklim değişikliği azaltım stratejisi ve eylem planı (2024-2023)*. 11 Aralık 2024'te [https://iklim.gov.tr/db/turkce/icerikler/files/%C4%B0klim%20De%C4%9Fi%C5%9Fikli%C4%9Fi%20Azalt%C4%B1m%20Stratejisi%20ve%20Eylem%20Plan%C4%B1%20\(2024-2030\).pdf](https://iklim.gov.tr/db/turkce/icerikler/files/%C4%B0klim%20De%C4%9Fi%C5%9Fikli%C4%9Fi%20Azalt%C4%B1m%20Stratejisi%20ve%20Eylem%20Plan%C4%B1%20(2024-2030).pdf) adresinden alındı.
- İklim Değişikliği Başkanlığı. (2023b). *İklim değişikliğine uyum stratejisi ve eylem planı (2024-2030)*. 11 Aralık 2024'te https://iklim.gov.tr/db/turkce/icerikler/files/%C4%B0klim%20De%C4%9Fi%C5%9Fikli%C4%9Fi%20Uyum%20Stratejisi%20ve%20Eylem%20Plan_%202024-2030.pdf adresinden alındı.
- Jonsson, P., Bennet, C., Eliasson, I., & Lindgren, E. S. (2004). Suspended particulate matter and its relations to the urban climate in Dar es Salaam, Tanzania. *Atmospheric Environment*, 38(25), 4175–4181.
- Kalkınma Ajansları Genel Müdürlüğü. (2019). *Nüfus yoğunluğu ve kentsel işlevler ile Türkiye'de ilçelerin kentleşme düzeyinin ölçülmesi*. 28 Kasım 2024'te <https://www.mevka.org.tr/assets/upload/dosyalar/turkiyede-ilcelerin-kentlesme-duzeyinin-olculmesi-raporu.pdf> adresinden alındı.
- Kaplan, G., Avdan, U., & Avdan, Z. Y. (2018). Urban heat island analysis using the Landsat 8 satellite data: A case study in Skopje, Macedonia. *Proceedings*, 2(7), Article 358. <https://doi.org/10.3390/ecrs-2-05171>
- Kızılaslan, N., & Arslan, F. (2022). Kırsaldan kente göç hareketlerinin nüfusun cinsiyet ve eğitim faktörlerine etkisi (Amasya ili örneği). *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 11(3), 147–158.
- Kim, Y., Yu, S., Li, D., Gatson, S. N., & Brown, R. D. (2022). Linking landscape spatial heterogeneity to urban heat island and outdoor human thermal comfort in Tokyo: Application of the outdoor thermal comfort index. *Sustainable Cities and Society*, 87, Article 104262. <https://doi.org/10.1016/j.scs.2022.104262>
- Korkut, A., Gültürk, P., & Topal, T. Ü. (2016). Kentsel peyzaj yapılarında zemin geçirimsizliği üzerine bir araştırma: Tekirdağ örneği. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, 16(2), 412–422.
- Kurdoğlu, B. Ç., & Kurt Konakoğlu, S. S. (2018). Amasya kent örneğinde rekreasyon alanları bilgi sistemi oluşturulmasına yönelik bir çalışma. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 19(1), 66–79.
- Kurdoğlu, B. Ç., & Kurt, S. S. (2017). Determination of greenway routes using network analysis in Amasya, Turkey. *Journal of Urban Planning and Development*, 143(1), Article 05016013. [https://doi.org/10.1061/\(ASCE\)UP.1943-5444.0000352](https://doi.org/10.1061/(ASCE)UP.1943-5444.0000352)
- Kurdoğlu, B. Ç., Demirel, Ö., Kalın, A., Kurt, S. S., Usta, Z., & Çelik, K. T. (2014). *Amasya kenti için Yeşilirmak koridorunu içine alan bir kentsel yeşilyol modeli oluşturmak* (TÜBİTAK Hızlı Destek Projesi Sonuç Raporu). TÜBİTAK.
- Kurdoğlu, B. Ç., Kurt Konakoğlu, S. S., Usta, Z., Çelik, K. T., Demirel, Ö., & Kalın, A. (2016). Amasya kent örneğinde yeşilyol güzergâhlarının AHP ile öncelikli işlevlerinin belirlenmesine yönelik bir çalışma. *Süleyman Demirel Üniversitesi Mimarlık Bilimleri ve Uygulamaları Dergisi*, 1(2), 21–30.
- Kurt, S. S. (2013). *Amasya kenti için Yeşilirmak koridorunu içine alan bir kentsel yeşilyol önerisi* [Yüksek lisans tezi, Karadeniz Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Landsberg, H. E. (1981). *The urban climate*. Academic Press.
- Liang, L., & Gong, P. (2020). Urban and air pollution: A multi-city study of long-term effects of urban landscape patterns on air quality trends. *Scientific Reports*, 10, Article 74524. <https://doi.org/10.1038/s41598-020-74524-9>
- Liu, C., Yang, K., Bennett, M. M., Guo, Z., Cheng, L., & Li, M. (2019). Automated extraction of built-up areas by fusing VIIRS nighttime lights and Landsat-8 data. *Remote Sensing*, 11(13), Article 1571. <https://doi.org/10.3390/rs11131571>
- Mathew, A., Sreekumar, S., Khandelwal, S., Kaul, N., & Kumar, R. (2016). Prediction of surface temperatures for the assessment of urban heat island effect over Ahmedabad city using linear time series model. *Energy and Buildings*, 128, 605–616. <https://doi.org/10.1016/j.enbuild.2016.07.004>

- Merzifon Belediyesi. (2024). *İmar Planı*. 11 Aralık 2024'te <https://merzifon.bel.tr/tag/imar-planı> adresinden alındı.
- Meteoroloji Genel Müdürlüğü. (2024a). *İklim sınıflandırmaları*. 30 Kasım 2024'te <https://mgm.gov.tr/iklim/iklim-siniflandirmalari.aspx?m=AMASYA> adresinden alındı.
- Meteoroloji Genel Müdürlüğü. (2024b). *İl ve ilçeler istatistik verileri*. 28 Kasım 2024'te <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=AMASYA> adresinden alındı.
- Mohan, M., Pathan, S. K., Narendrareddy, K., Kandya, A., & Pandey, S. (2011). Dynamics of urbanization and its impact on land-use/land-cover: A case study of megacity Delhi. *Journal of Environmental Protection*, 2(9), 1274–1283.
- Nakata, C. M., & Souza, L. C. (2013). Verification of the influence of urban geometry on the nocturnal heat island intensity. *Journal of Urban and Environmental Engineering*, 7(2), 286–292.
- Oke, T. R. (1973). City size and the urban heat island. *Atmospheric Environment*, 7(8), 769–779.
- Ostertagová, E. (2012). Modelling using polynomial regression. *Procedia Engineering*, 48, 500–506.
- Özdemir, Z., & Özkaynak Yolcu, M. (2023). Kentli hakkı kapsamında kamusal yeşil alanların erişilebilirliğinin incelenmesi: Amasya kenti örnekleme. *Amasya Üniversitesi Sosyal Bilimler Dergisi*, 8(14), 329–375.
- Özmeçik, İ. M., Ersoy Tonyaloğlu, E., & Göktuğ, T. H. (2022). Kent atlası verilerinden kentsel saçaklanmanın belirlenmesi: Samsun ili örneği. *Türkiye Peyzaj Araştırmaları Dergisi*, 5(2), 102–111.
- Santamouris, M., Cartalis, C., & Synnefa, A. (2015). Local urban warming, possible impacts and a resilience plan to climate change for the historical center of Athens, Greece. *Sustainable Cities and Society*, 19, 281–291.
- Sarı, V. İ., Gökyurt, F., & Doğan, T. (2020). Türkiye'de ilçelerin kentleşme düzeyinin ölçülmesi. *Şehir ve Medeniyet Dergisi*, 136–162.
- Sarrat, C., Lemonsu, A., Masson, V., & Guedalia, D. (2006). Impact of urban heat island on regional atmospheric pollution. *Atmospheric Environment*, 40, 1743–1758.
- Simmel, G. (1996). Metropol ve tinsel yaşam. *Cogito Üç Aylık Düşünce Dergisi*, 8, 81–91.
- Şenol, E. (2014). Amasya kentinin Cumhuriyet dönemi mekânsal gelişimi ve tarım alanlarının amaç dışı kullanımı. *Uluslararası Sosyal Araştırmalar Dergisi*, 7(30), 1307–9581.
- T.C. Amasya İl Kültür ve Turizm Müdürlüğü. (2024). *Amasya'nın iklim özellikleri*. 21 Kasım 2024'te <https://amasya.ktb.gov.tr/TR-59460/iklim.html> adresinden alındı.
- T.C. Amasya Valiliği Çevre ve Şehircilik İl Müdürlüğü. (2013). *Amasya ili kentleşme ve mekânsal inceleme raporu 2013*. https://webdosya.csb.gov.tr/db/amasya/haberler/haberler11213_1.pdf
- T.C. Amasya Valiliği Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü. (2024). *Amasya ili 2023 yılı çevre durum raporu*. https://webdosya.csb.gov.tr/db/ced/icerikler/amasya_cdr2023-20241022130528.pdf
- T.C. Amasya Valiliği İl Afet ve Acil Durum Müdürlüğü. (2021). *İl afet risk azaltma planı*. 21 Kasım 2024'te <https://amasya.afad.gov.tr/kurumlar/amasya.afad/planlar/AMASYAIRAP.pdf> adresinden alındı.
- T.C. Amasya Valiliği. (2023). *Amasya İli, Merzifon İlçesi Sofular Mahallesi içerisinde yer alan 1480 ada 244 parseli kapsayan rezerv yapı alanına ilişkin 1/500 ölçekli nazım imar planı açıklama raporu*. 12 Aralık 2024'te <https://webdosya.csb.gov.tr/db/amasya/duyurular/amasya-5000-plan-aciklama-raporu-20230120123730.pdf> adresinden alındı.
- T.C. İstanbul Büyükşehir Belediyesi. (2023). *İklim değişikliği izleme raporu 2023*. İstanbul Büyükşehir Belediyesi Çevre Koruma ve Kontrol Dairesi Başkanlığı. 21 Kasım 2024'te <https://cevre.ibb.istanbul/wp-content/uploads/2024/11/2023-İKLİM-DEĞİŞİKLİĞİ-İZLEME-RAPORU-11.11.2024-Filigranlı-TR.pdf> adresinden alındı.
- Tıkansak, T. E. (2014, 8-11 Mayıs). *Kentsel dönüşüm ve sürdürülebilirlik* [Bildiri sunumu]. 1. Uluslararası Kentsel Planlama-Mimarlık-Tasarım Kongresi: Kentsel Dönüşüm Ekonomik, Sosyal ve Fiziksel Yönü, Kocaeli, Türkiye.
- Tolon, M., & Tosunoğlu, N. G. (2008). Tüketici tatmini verilerinin analizi: Yapay sinir ağları ve regresyon analizi karşılaştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 247–259.
- Topal, T. Ü. (2023). Evaluation of the relationship between spatial-temporal changes of land use/land cover (LULC) and land surface temperature (LST): A case study of Nilüfer, Bursa. *Turkish Journal of Landscape Research*, 6(1), 56–74.
- Topal, T. Ü., & Yılmaz, R. (2024, December 14-16). *Mapping ground imperviousness conditions in urban areas and analyzing temporal-spatial changes: The case of Süleymanpaşa District, Tekirdağ Province* [Congress presentation]. 3rd International Paris Applied Science Congress, Paris, France.
- Türkiye İstatistik Kurumu. (2022). *Dünya Nüfus Günü*. 28 Kasım 2024'te <https://data.tuik.gov.tr/Bulten/Index?p=Dunya-Nufus-Gunu-2024-53680#:~:text=T%C3%BCrkiye%2C%2085%20milyon%20372%20bin,1%2C1'ini%20olu%C5%9Fturdu> adresinden alındı.
- Türkiye İstatistik Kurumu. (2024a). *AMASYA Demografik Göstergeler İl Bilgi Kartı*. 28 Kasım 2024'te <https://nip.tuik.gov.tr/?value=İlGostergeKartlari> adresinden alındı.
- Türkiye İstatistik Kurumu. (2024b). 7 Şubat 2025'de <https://data.tuik.gov.tr/Kategori/GetKategori?p=Nufus-ve-Demografi-109> adresinden alındı.
- United Nations. (2024). *World population projected to reach 9.8 billion in 2050 and 11.2 billion in 2100*. <https://www.un.org/en/desa/world-population-projected-reach-98-billion-2050-and-112-billion-2100>

- UZF Center for Environmental Research. (2004). *Making greener cities: A practical guide*. <https://www.yumpu.com/en/document/read/4425328/making-greener-cities-urge-ufz>
- Wemegah, C. (2020). *Systematic assessment of Urban Heat Island (UHI) warming in Greater Accra Region* [Master's thesis, Kwame Nkrumah University]. <https://doi.org/10.13140/RG.2.2.11121.51040>
- Weng, Q., & Yang, S. (2006). Urban air pollution patterns, land use, and thermal landscape: An examination of the linkage using GIS. *Environmental Monitoring and Assessment*, 117, 463–489.
- World Health Organization. (2018). *COP24 Special Report: Health & Climate Change*. <https://iris.who.int/bitstream/handle/10665/276405/9786057496713-tur.pdf>
- Yan, X., & Su, X. (2009). *Linear regression analysis: Theory and computing*. World Scientific.
- Yao, L., Yang, X., Zhu, C., Jin, T., Peng, L. L., & Ye, Y. (2017). Evaluation of a diagnostic equation for the daily maximum urban heat island effect. *Procedia Engineering*, 205, 2863–2870.
- Yıldız, M., & Kavzođlu, T. (2012, 16–19 Ekim). Nesne tabanlı sınıflandırma tekniđi ile arazi örtüsünün belirlenmesi: QuickBird ve Landsat örneđi [Bildiri sunumu]. IV. UZAL-CBS Sempozyumu, Zonguldak, Türkiye.
- Yuan, Y., Xi, C., Jing, Q., & Felix, N. (2017). Seasonal variations of the urban thermal environment effect in a tropical coastal city. *Advances in Meteorology*, 2017, 1–18. <https://doi.org/10.1155/2017/8917310>
- Zhou, D., Zhao, S., Liu, S., Zhang, L., & Zhu, C. (2014). Surface urban heat island in China's 32 major cities: Spatial patterns and drivers. *Remote Sensing of Environment*, 152, 51–61. <https://doi.org/10.1016/j.rse.2014.05.017>
- Zhou, W., Pickett, S. T. A., & Cadenasso, M. L. (2016). Shifting concepts of urban spatial heterogeneity and their implications for sustainability. *Landscape Ecology*, 32, 15–30. <https://doi.org/10.1007/s10980-016-0432-4>

Ayçiçeği Çiçek Tablalarının Mask R-CNN Derin Sinir Ağı ile RGB ve Multispektral İHA Ortomozaiklerinden Örnek Segmentasyonu

Instance Segmentation of Sunflower Inflorescences from RGB and Multispectral UAV Orthomosaics with Mask R-CNN Deep Neural Network

Esra Yıldırım^{1*}, İsmail Çölkesen¹, Umut Güneş Sefercik¹

¹Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 41400, Kocaeli/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Esra Yıldırım
esrayildirim@gtu.edu.tr

doi: 10.48123/rsgis.1602369

Yayın süreci

Geliş tarihi: 16.12.2024
Kabul tarihi: 13.02.2025
Basım tarihi: 26.03.2025

Özet

Ayçiçeği, ülkemiz için önemli bir yağlı tohum kaynağı olup, büyük ve kendine özgü çiçek tablasıyla diğer tarımsal bitkilerden ayrılır. Ayçiçeği tablasının doğru bir şekilde tespit edilmesi, verim tahmini ve sürdürülebilir üretim planlaması açısından çok önemlidir. Bu çalışmanın temel amacı, derin öğrenme tabanlı Mask R-CNN modelinin RGB ve multispektral İHA ortomozaiklerinden ayçiçeği çiçek tablasını tespit etme performansının değerlendirilmesidir. Bu amaçla, Sakarya'nın Arifiye ilçesindeki çalışma alanı üzerinde İHA hava fotoğrafları toplanmış ve yüksek çözünürlüklü ortomozaikler üretilmiştir. ResNet-50 omurgalı Maske R-CNN modeli, RGB ve multispektral İHA ortomozaiklerinden manuel olarak etiketlenmiş veri kümeleri üzerinde eğitilmiş ve test edilmiştir. Sonuçlar, modelin multispektral verilerle daha yüksek doğruluk elde ettiğini, tahmin edilen ve gerçek tespitler arasındaki örtüşmeyi ölçen 0,50 birleşim üzerinde kesişim eşiğinde %94,74 Ortalama Hassasiyete ve %96,73 F1 Skoruna ulaştığını göstermektedir. RGB verileriyle, model en iyi performansı 0,75 eşiğinde göstererek %78,19 F1 Skoru ve %63,50 Ortalama Hassasiyet elde etmiştir. Bu bulgular, multispektral İHA verilerinin ayçiçeği çiçek tablalarının tespit edilmesinde daha etkili olduğunu, RGB İHA verilerinin ise daha iyi lokalizasyon doğruluğu sağladığını göstermektedir.

Anahtar kelimeler: Derin öğrenme, Örnek segmentasyonu, Mask R-CNN, İnsansız hava aracı (İHA), Hassas tarım, Ayçiçeği

Abstract

Sunflower is an important oilseed source for our country, distinguished from other agricultural plants by its large and unique inflorescence. Accurately detecting sunflower inflorescence is crucial for yield estimation and sustainable production planning. The main goal of this study is to evaluate the performance of the deep learning-based Mask R-CNN model in detecting sunflower inflorescences from RGB and multispectral UAV orthomosaics. For this purpose, UAV aerial photos were captured over the study area in Arifiye district of Sakarya, and high-resolution orthomosaics were produced. The Mask R-CNN model with a ResNet-50 backbone was trained and tested on manually labeled datasets from RGB and multispectral UAV orthomosaics. The results indicate that the model achieved higher accuracy with multispectral data, reaching an F1 Score of 96.73% and an Average Precision of 94.74% at a 0.50 intersection over union threshold, which measures the overlap between predicted and actual detections. With RGB data, the model performed best at a 0.75 threshold, obtaining an F1 Score of 78.19% and an Average Precision of 63.50%. These findings suggest that multispectral UAV data are more effective in detecting sunflower inflorescences, while RGB UAV data provide better localization accuracy.

Keywords: Deep learning, Instance segmentation, Mask R-CNN, Unmanned aerial vehicle (UAV), Precision agriculture, Sunflower

1. Giriş

Ayçiçeği (*Helianthus annuus* L.) dünyanın farklı bölgelerinde yaygın olarak yetiştirilen, ekonomik, tıbbi ve besin değeri yüksek bir tarımsal üründür. Ülkemizde ekimi yapılan yağlı tohumlu bitkiler arasında üretim bakımından birinci sırayı alan yağlık ayçiçeği, bitkisel yağ tüketiminde %80-85 civarındaki payı nedeniyle ülkemizin en önemli yağlı tohum bitkisidir (Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü, 2023). Bitki, plastik, kimya, boya, sabun, kozmetik, motor yağı, cila ve biyodizel sanayi için de önemli bir hammadde olmakla birlikte küspesi hayvan yemi üretimi için kullanılmaktadır. Ayçiçeği, belirgin şekilde büyük bir çiçek tablasına sahip tek bir gövdesi ile diğer tarım bitkilerinden ayrılabilir. Çiçek tablasının sayısı ve boyutu, verimi ve tohum kalitesini doğrudan etkileyen kritik tarımsal özelliklerdir (Seiler, 1997). Dolayısıyla çiçek tablasının doğru ve hassas bir şekilde tespiti, verim tahminlemesi, fenotip analizi, fenolojik takip ve sürdürülebilir üretim planlaması için önemlidir (Jing vd., 2024). Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) verilerine göre Dünya'da ayçiçeği üretimi 1961'de 6,7 milyon hektar alanda ekilen 6,8 milyon ton iken, 2022'de 29,3 milyon hektarda ekilen 54,3 milyon ton olarak gerçekleşmiştir (Food and Agriculture Organization, 2022). Dünya'daki ayçiçeği üretimi göz önüne alındığında 2022 yılı itibarıyla en büyük paya 16,4 milyon ton ile Rusya sahipken Türkiye 2,6 milyon ton ile beşinci sırada yer almaktadır (Food and Agriculture Organization, 2022). Türkiye İstatistik Kurumu (TÜİK) verilerine göre Türkiye'de ayçiçeği ekim alanları 2004 yılında 5,5 milyon dekar iken, 2023 yılı itibarıyla ekili alan miktarı %73 artış göstererek 9,5 milyon dekar olarak gerçekleşmiştir (Türkiye İstatistik Kurumu, 2023). Üretim ise 2004 yılında 0,9 milyon ton iken, 2023 yılı itibarıyla %144 artış ile 2,2 milyon ton olarak gerçekleşmiş ve dolayısıyla birim alandan elde edilen verim %137 artış göstererek 498 kg/dekara ulaşmıştır (Türkiye İstatistik Kurumu, 2023). Öte yandan, birincil olarak insanlar için önemli bir besin kaynağı olan yenilebilir yağların çıkarılması için yetiştirilen yağlı tohumlu bitkiler arasında üretimin yaklaşık %80'ini oluşturan ayçiçeğinin ürün verimindeki farklılıkların gıda sektörünü ve ülke ekonomisini önemli ölçüde etkileyeceği açıktır. Bu bağlamda, sensör teknolojileri ve yapay zekâ destekli akıllı tarım uygulamaları; ürün ekim kalitesinin analizi, fenolojik evre takibi, verim tahmini, hastalık tespit ve takibi, yetiştirme programlarının düzenlenmesi, gelecek ekim takvimleri için ürün yönetiminde karar verme noktasında sürdürülebilir üretim ve tarla yönetiminde büyük rol oynamaktadır (Centorame vd., 2024a; Centorame vd., 2024b).

Dünya çapında hızlı nüfus artışı ve sanayileşme gibi faktörler nedeniyle ayçiçeği dahil olmak üzere birçok tarımsal üründe üretim artışı yaşanmaktadır. Artan üretim talepleri doğrultusunda hassas tarım; tarımsal üretimi artırmak, işgücünü azaltmak, gübre ve sulama süreçlerinin etkin yönetimini içerisine alan önemli hususlarda dünya çapında benimsenen bir kavram olarak ortaya çıkmıştır (Singh vd., 2020). 2024'te Uluslararası Hassas Tarım Topluluğu (ISPA) hassas tarımı, zamansal, mekânsal ve bireysel bitki ve hayvan verilerini toplayan, işleyen ve analiz eden ve bunları tarımsal üretimin gelişmiş kaynak kullanımı verimliliğini, üretkenliğini, kalitesini, kârlılığını ve sürdürülebilirliğini artırmak için tahmini değişkenliğe göre yönetim kararlarını desteklemek üzere diğer bilgilerle birleştiren bir yönetim stratejisi olarak tanımlamıştır (International Society of Precision Agriculture, 2024). Bu bağlamda, bitki örtüsünün gelişimi, verimi, sağlığı, fiziko-kimyasal içeriği, besin durumu, toprak durumu, gübre ve ilaç etkisi gibi değişkenlerin gözlemlenmesi ve ölçülmesi için uzaktan algılama ve yapay zekâ gibi yeni gelişen teknolojiler hassas tarım uygulamaları için önemli birer araç olarak kullanılmaktadır (Singh vd., 2020).

Uzaktan algılama teknolojileri, dünya yüzeyinin doğal ve yapay özellikleri hakkında hedef objelerle doğrudan fiziksel temas kurmadan yüksek konumsal, spektral, radyometrik ve zamansal çözünürlüklerde veri toplamaya olanak tanıdığından uzaktan algılanmış veriler hızlı, hassas ve dinamik tarım uygulamalarında önemli bir kaynak durumundadır. Bu uygulamalar arasında sürdürülebilir üretim planlaması ve yüksek doğrulukta verim tahminlemesi için büyük önem arz eden tarımsal ürünlerin tespiti, takibi, fenolojik gelişiminin izlenmesi, sağlığı ve hastalıklarının takibi üzerine gerçekleştirilen çalışmalar öne çıkmaktadır. Söz konusu çalışmaların gerçekleştirilmesinde literatürde özellikle uydu ve İnsansız Hava Aracı (İHA) verileri temel altlık olarak kullanılmaktadır. Ancak, uydu sensörlerinin mekânsal, spektral ve zamansal çözünürlüğündeki gelişmelere rağmen yüksek maliyeti, bulut ve sis problemi (optik uydularda), gerçek zamanlı veri alınamaması gibi problemler hassas tarımsal uygulamalarda uydu görüntülerinin kullanımını kısıtlamaktadır. Buna karşın İHA teknolojileri uygun maliyetli olmaları, ihtiyaç duyulan verileri ihtiyaç duyulan zamanda ve yerde istenilen görüntüleme geometrilerinde (nadir bakışlı, oblik, polinomal, grid, çift-grid, dairesel vb.) elde edebilmeleri, uydular ve diğer uzaktan algılama platformlarına kıyasla alçak uçuş irtifaları sayesinde daha yüksek mekânsal çözünürlük sağlayabilmeleri ve periyodik veri alım kabiliyetleri gibi nedenlerle tarımsal uygulamalarda büyük avantajlar sağlamaktadır (Bouguettaya vd., 2022). Bu doğrultuda, İHA teknolojileri tarımsal ürünlerin tespiti ve haritalanması (Popescu vd., 2020), verim tahmini (Yang vd., 2019), hastalık tespiti (Guo vd., 2021) ve yabancı ot tespiti (Huang vd., 2018) gibi çeşitli hassas tarım çalışmalarında literatürde yaygın olarak kullanılmaktadır.

Tarımsal ürünlerin tespiti ve izlenmesinde geleneksel görüntü işleme yaklaşımları yaygın olarak kullanılsa da manuel özellik çıkarımı gereksinimi bu yaklaşımların kullanılabilirliğini kısıtlamaktadır. Geleneksel yaklaşımlarda görüntü üzerinde ilgi duyulan nesnelere ilişkin özellikler renk, doku ve morfolojik işlemler kullanılarak çıkarılmaktadır (Bakhshipour vd., 2018). Ancak arka plan, aydınlanma, toprak rengi, gölge, bitkinin baş kısmının şekli ve boyutu gibi çeşitli faktörler bu nesnelere otomatik tespitini etkileyebilmektedir (Karami vd., 2021).

Literatürde sunulan çeşitli yöntemler bu etkilerin azaltılmasını hedeflese de bu yaklaşımların gerçek dünya koşulları ve karmaşık yapılı veri setlerine uygulanabilirliğini sağlamak halen önemli bir sorun olarak varlığını sürdürmektedir (Sanaeifar vd., 2023). Son yıllarda, derin öğrenme yaklaşımının ortaya çıkmasıyla birlikte, görüntü segmentasyonu, nesne tespiti ve görüntü sınıflandırma gibi görüntü işleme uygulamalarında önemli başarılar elde edilmiştir (Redmon vd., 2016; Badrinarayanan vd., 2017; Yang vd., 2018). Derin öğrenme algoritmaları, derin bir sinir ağı oluşturarak kendi kendine öğrenme yaklaşımıyla verilerden otomatik ve uyarlanabilir bir şekilde görüntü üzerinde aranan nesneye ilişkin özellikleri çıkarabilme kabiliyetine sahiptir. Bu avantajı sayesinde geleneksel yöntemler ve uzman deneyimine dayalı olarak gerçekleştirilen nesne tespiti çalışmalarında karşılaşılan sorunların üstesinden gelebilmektedir. Örneğin, bir evrimsel sinir ağı (ESA) mimarisi olan AlexNet'in, 2012'deki ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'ndaki üstün başarısıyla ESA'ların görüntü işleme alanındaki uygulamaları popülerlik kazanmaya başlamış ve güçlü özellik temsil yetenekleri nedeniyle uzaktan algılanan görüntülerden tarımsal ürün tespiti gibi hassas tarım uygulamalarında yaygın olarak kullanılmaya başlanmıştır (Albahar, 2023; Kamilaris & Prenafeta-Boldú, 2018).

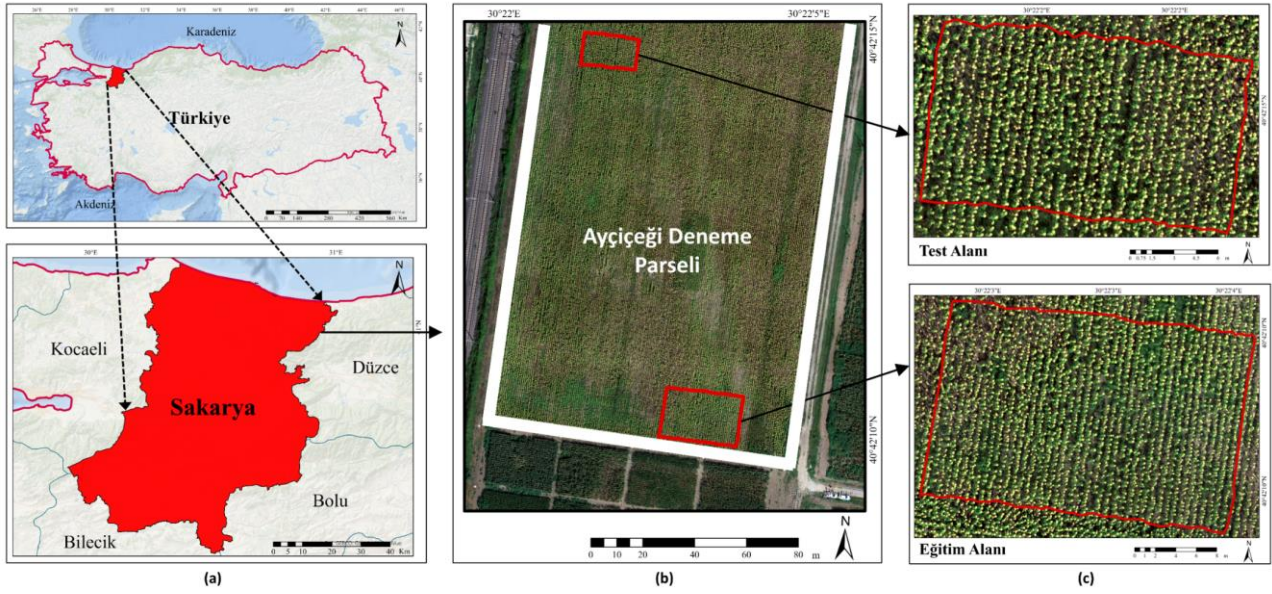
İHA teknolojisi ve derin öğrenme kombinasyonu tarımsal ürünün tespiti, ürünlerin fiziksel ve spektral yapısı, hastalık/zarar durumu ve toprak türü gibi hususlarda anlık bilgi sağlayabilmektedir (Bouguettaya vd., 2022). İHA tabanlı uzaktan algılama görüntüleri ve derin öğrenme tekniklerini kullanan hassas ve otomatik tarımsal ürün tespiti; ürün haritalama ve izleme (Xiao vd., 2023), ürün verim tahmini (Yang vd., 2019), su stresi izleme (Gao vd., 2020), hastalık/böceklenme tespiti (Kerkech vd., 2018) dahil olmak üzere birçok hassas tarım uygulaması için anahtar bir role sahiptir. Bu bağlamda, literatürde birçok çalışma ayçiçeği çiçek tablalarının (kapitulum) tespiti, ayçiçeği büyüme aşamalarının tespiti, tıbbi bitki tespiti gibi uygulamalarda İHA verileri ve derin öğrenme algoritmalarının entegrasyonunu önermektedir. Örneğin, Jing vd. (2024) RGB İHA görüntülerinden ayçiçeği kapitulumlarının tespitinde iyileştirilmiş bir YOLOv7-Tiny yaklaşımının kullanımını ele almıştır. Ayçiçeğinin büyüme aşamalarının tespiti için Song vd. (2023) DeepLab V3 +, SegNet ve PSPNet semantik segmentasyon ağları ve multispektral İHA görüntülerinden yararlanmıştır. Diğer bir çalışmada, Poleshchenko vd. (2023) İHA görüntülerinden ayçiçeği bitkisinin segmentasyonunda U-Net ve FPN mimarilerinin performansını incelemiştir. Ding vd. (2023) tarafından gerçekleştirilen uygulamada, İHA ortomozaiklerinden tıbbi bitkilerin tespiti ve verim tahminlemesi için Mask R-CNN modeli kullanılmıştır. Li vd. (2023), kanola bitkisi çiçek tablasının RGB İHA ortofotolarından tespiti ve verim tahminlemesini amaçlayan çalışmada YOLOv5 tabanlı bir yaklaşım geliştirmiştir. Farklı fenolojik aşamalardaki ayçiçeklerinin çok zamanlı RGB İHA ortomozaiklerinden tespitine yönelik gerçekleştirilen güncel bir çalışmada ise U-Net ve DeepLab V3 derin semantik segmentasyon ağlarının performansı ele alınmıştır (Yıldırım vd., 2024a).

Bu çalışmanın temel amacı ayçiçeği çiçek tablalarının İHA ortomozaiklerinden tespitinde derin öğrenme tabanlı örnek segmentasyonu modeli Mask R-CNN'in performansının araştırılması ve model eğitiminde veriseti olarak RGB ve multispektral ortomozaiklerin kullanılmasının modelin tespit doğruluğu üzerindeki etkilerinin incelenmesidir. Mask R-CNN, obje tespit ve segmentasyon aşamalarını birleştirerek tespit edilen her bir nesne örneği için piksel düzeyinde segmentasyon maskesi üretebilmektedir. Bu çalışmada tercih edilmiş olmasının temel sebepleri ise ayçiçeği çiçek tablalarının tespitinde piksel bazında hassas bir şekilde nesne sınırlarını belirleyebilmesi ve literatürde ayçiçeği özelinde kullanılmamış bir model olmasıdır. Çalışmanın amaçları doğrultusunda, Sakarya ili Arifiye ilçesinde belirlenen bir çalışma alanının RGB ve multispektral hava fotoğrafları İHA uçuşları ile toplanmış ve yüksek çözünürlüklü ortomozaikler üretilmiştir. Oluşturulan her iki ortomozaik üzerindeki ayçiçeği çiçek tablaları ArcGIS Pro yazılımında manuel olarak etiketlenmiş ve ortomozaikler 256×256 piksel boyutunda görüntü parçalarına bölünerek iki farklı veriseti oluşturulmuştur. Oluşturulan verisetleri ile Mask R-CNN modeli ResNet-50 omurga ağı ile birleştirilerek transfer öğrenme yaklaşımıyla eğitilmiş ve modelin farklı spektral ve mekânsal çözünürlüklere sahip veri setleri kullanımında ayçiçeği çiçek tablası tespitine yönelik performansı irdelenmiştir.

2. Çalışma Alanı

Çalışma, Sakarya ili Arifiye ilçesinde, Sakarya Mısır Araştırma Enstitüsü tarafından yönetilen parseller içerisinde yer alan bir ayçiçeği tarlasında yürütülmüştür. Sakarya ili, Türkiye'nin kuzeybatısında 29°57' ve 30°53' doğu boylamları ile 40°17' ve 41°13' kuzey enlemleri arasında yer almakta olup kuzeyden Karadeniz, doğudan Düzce ili, güneydoğudan Bolu ili, güneyden Bilecik ili, batıdan Kocaeli ili ile çevrilidir (Şekil 1a). Karadeniz ve Akdeniz iklimlerinin etki gösterdiği bir geçiş iklim alanı olan ilde yazlar sıcak ve nemli, kışlar ise yağışlı ve ılıktır. Yüzölçümü 5.015 km² olan ve %44'ü platolar, %34'ü dağlar ve %22'si ovalardan oluşan ilde tarla bitkileri ile sebze ve meyve yetiştirilen tarım alanları il topraklarının yaklaşık %48'ini kapsamaktadır (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2024). Sahip olduğu zengin bitki örtüsünün başında ormanlar gelmekle birlikte ilde buğday, patates, kabak, pancar, mısır, ayçiçeği ve fındık gibi önemli tarımsal ürünler yetişmektedir. 10.970 tonluk ayçiçeği üretimi ile Sakarya ili, Türkiye ayçiçeği üretiminin %0,57'sini karşılamaktadır (Türkiye İstatistik Kurumu, 2023). Ayçiçeği farklı iklim koşullarında ve toprak türlerinde yetiştirilebilmesi sayesinde güçlü bir adaptasyona sahip ve toprağın derinliklerine kadar inebilen kök yapısı nedeniyle kuraklığa nispeten dayanıklı bir bitkidir (T.C. Tarım ve Orman Bakanlığı, 2007).

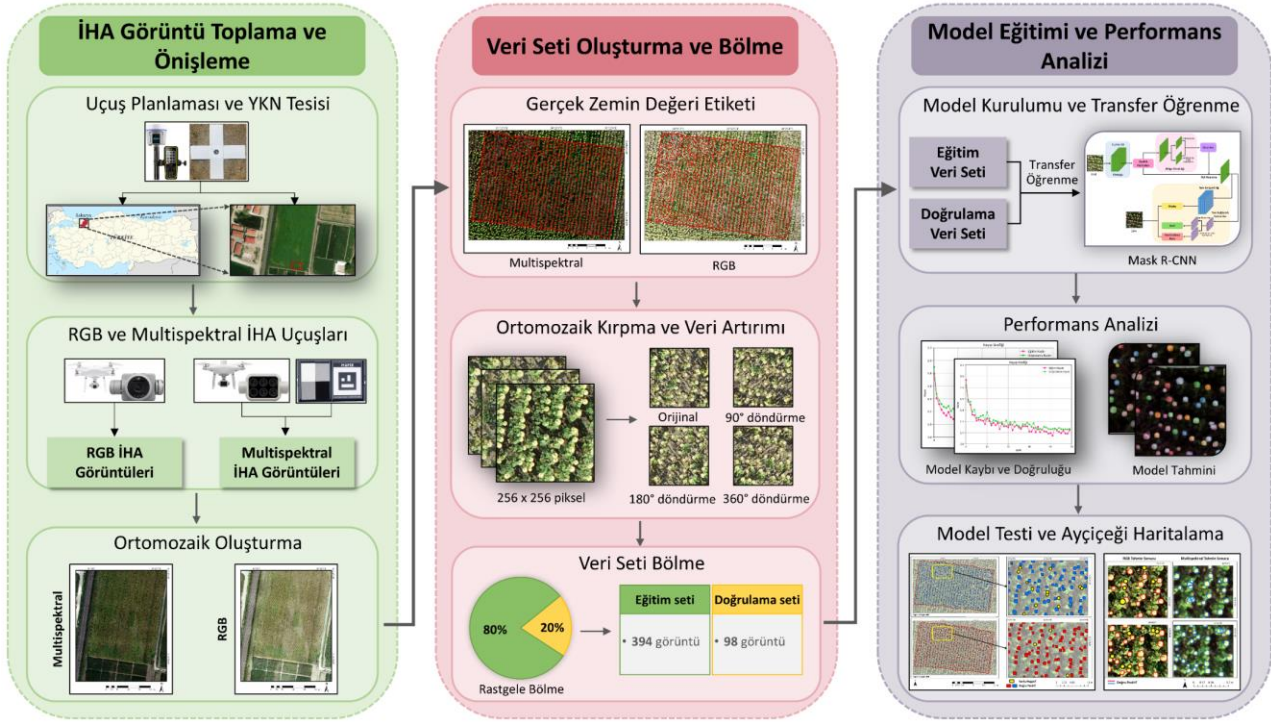
Bitki gelişimine göre ayçiçeği büyümesi iki ana aşamada gerçekleşir: (i) vejetatif evre (vegetative stage), (ii) üreme evresi (reproductive stage) (Schneider & Miller, 1981). Vejetatif evre (V), çıkış evresi (VE) ve gerçek yaprak gelişimi (V(N)) olmak üzere iki alt aşamaya ayrılır. Üreme evresi (R) bitki çiçek tablasının ilk oluşumu ile başlayan ve bitki fizyolojik olgunluğunun tamamlanmasıyla son bulan dokuz alt evrede gerçekleşir. Bu çalışmada, Sakarya Mısır Araştırma Enstitüsü tarafından yönetilen Kirazca Tarımsal Araştırma Alanı'nda üreme aşamasındaki ayçiçeği bitkisinin çiçek tablalarının tespiti amacıyla arazi çalışmaları yürütülmüş ve deneysel araştırmalarda kullanılmak üzere tasarlanan ayçiçeği tarlasında eğitim ve test bölgeleri oluşturulmuştur (Şekil 1b ve 1c).



Şekil 1. Çalışma alanı konumu: (a) Sakarya ili haritası, (b) Kirazca tarımsal araştırma alanı ayçiçeği tarlası, (c) eğitim ve test için tasarlanan deneysel sahalar

3. Metodoloji

Derin öğrenme ve İHA teknolojilerinin entegrasyonu ile ayçiçeği çiçek tablasının tespitini amaçlayan bu çalışmada derin öğrenme modeli olarak Mask R-CNN değerlendirmeye alınırken; temel veri kaynağı olarak RGB ve multispektral İHA ortomozaikleri kullanılmıştır. Bu amaç doğrultusunda spesifik olarak derin öğrenme modelinin farklı spektral ve mekânsal çözünürlüklere sahip verilerin kullanımına ilişkin ürün tespit performansı detaylı olarak incelenmiştir. Çalışma amacına uygun olarak takip edilen metodoloji üç temel işlem adımından oluşmaktadır: (1) RGB ve multispektral İHA hava fotoğraflarının toplanması, fotogrametrik işleme ve ortomozaik üretimi, (2) ortomozaikler üzerinde manuel etiketleme ile gerçek zemin verisi oluşturulması, ortomozağin kırılması, veri artırımı ve veri setinin eğitim ve test veri setlerine bölünmesi, (3) Mask R-CNN modelinin kurulumu, hiperparametre optimizasyonu, transfer öğrenme yaklaşımıyla modelin eğitimi ve validasyonu, performans analizi ve modelin test edilmesi. Çalışmaya ait detaylı iş akış şeması Şekil 2'de verilmiştir.




Şekil 2. Çalışma kapsamında izlenen iş akış şeması

3.1. İHA Veri Toplama ve Ortomozaik Üretimi

İHA teknolojisi ile veri toplama yöntemleri, ihtiyaç duyulan veri ve sonuç ürünlerin niteliğine göre farklılık göstermektedir. Bu çalışmada, Mask-R CNN modelinin RGB ve multispektral İHA hava fotoğraflarından üretilen ortomozaikler üzerinde açıkçeği çiçek tablasının otomatik tespit performansının ayrı ayrı değerlendirilmesi öncelikli hedef olarak belirlenmiştir. Bu hedef doğrultusunda, çalışma alanında hem RGB hem de multispektral İHA uçuşları ayrı ayrı gerçekleştirilmiş ve elde edilen yüksek çözünürlüklü hava fotoğraflarıyla en yüksek kalitede ortomozaiklerin üretimi amaçlanmıştır. RGB veri alımı için 20 MP çözünürlüklü ve 8,8 mm odak uzaklıklı Sony Exmor RGB kamerası sahip DJI Phantom 4 Pro V2 İHA, multispektral veri alımı içinse 2,08 MP çözünürlüklü ve 5,74 mm odak uzaklıklı DJI Phantom IV Multispektral İHA kullanılmıştır. İHA uçuşları, 29 Ağustos 2022 tarihinde, 50 m irtifada, %80 boyuna ve %60 enine bindirme oranlarıyla gerçekleştirilmiştir. RGB İHA uçuşları, açıkçeklerinin 3B fiziksel yapısını her cepheden bakışla daha yüksek potansiyelde tasvir edebilmek amacıyla hem kuzey-güney hem de doğu-batı yönlü rotaları içerecek şekilde çift-grid (double-grid) modda ve 70° bakış açısında planlanmıştır. Multispektral İHA uçuşlarında ise RGB banda ek olarak ayrı ayrı R, G, B bant yanı sıra kırmızı kenar (red edge) ve yakın kızılötesi (NIR) görüntüleme ile spektral imza tasviri ön planda olduğundan poligonal modda kuzey-güney yönlü ve nadir bakışlı (90°) uçuşlar planlanmıştır. Uygulanan uçuş parametreleri doğrultusunda, oluşturulacak stereo modellerin her bölgesinin en az 9 hava fotoğrafı ile temsili sağlanmış, RGB ve multispektral hava fotoğrafları sırasıyla ~1,47 cm ve ~3,23 cm ortalama yer örnekleme aralıklı (YÖA) olarak elde edilmiştir. Elde edilen hava fotoğraflarının fotogrametrik işlemesi, Agisoft Metashape yazılımında gerçekleştirilmiştir. RGB ve multispektral hava fotoğraflarının karşılıklı yönlendirilmesi hareketten yapı (SfM) tekniği temelinde otomatik eşleştirme ile gerçekleştirilirken mutlak yönlendirmede arazide uçuş öncesinde tesis edilmiş 14 polikarbon mobil yer kontrol noktası (YKN) kullanılmıştır. Normal şartlarda, multispektral veri alımının gerçekleştirildiği İHA, gerçek zamanlı kinematik global navigasyon uydu sistemleri (RTK GNSS) alıcı anten donanımına sahip olduğundan YKN kullanım gereksinimi bulunmamaktadır. Ancak, İHA'lar üzerinde yer alan düşük maliyetli RTK GNSS donanımlarında bazı hava ve topoğrafya şartlarında sinyal kalitesinde düşüşler yaşanabilmekte hatta kesintiler oluşabilmekte ve pozisyonlama doğruluğu düşebilmektedir (Sefercik vd., 2024). Bu doğrultuda, çalışma alanının çok yakınında bulunan yüksek hızlı tren hattının RTK GNSS sinyali üzerinde oluşturabileceği olumsuz etkiler (sinyal kesilmesi, gecikmesi vb.) göz önünde tutularak geometrik yönlendirmede RGB İHA ile eşit koşullar sağlanması amacıyla multispektral İHA verilerinin mutlak yönlendirmesinde de arazide tesis edilmiş YKN'ler kullanılmıştır. RGB ve multispektral hava fotoğraflarının mutlak yönlendirmelerinde kullanılan YKN'lerin ortalama karesel ortalama hataları (KOH) sırasıyla $\pm 1,5$ cm ve $\pm 1,1$ cm olarak tespit edilmiştir.

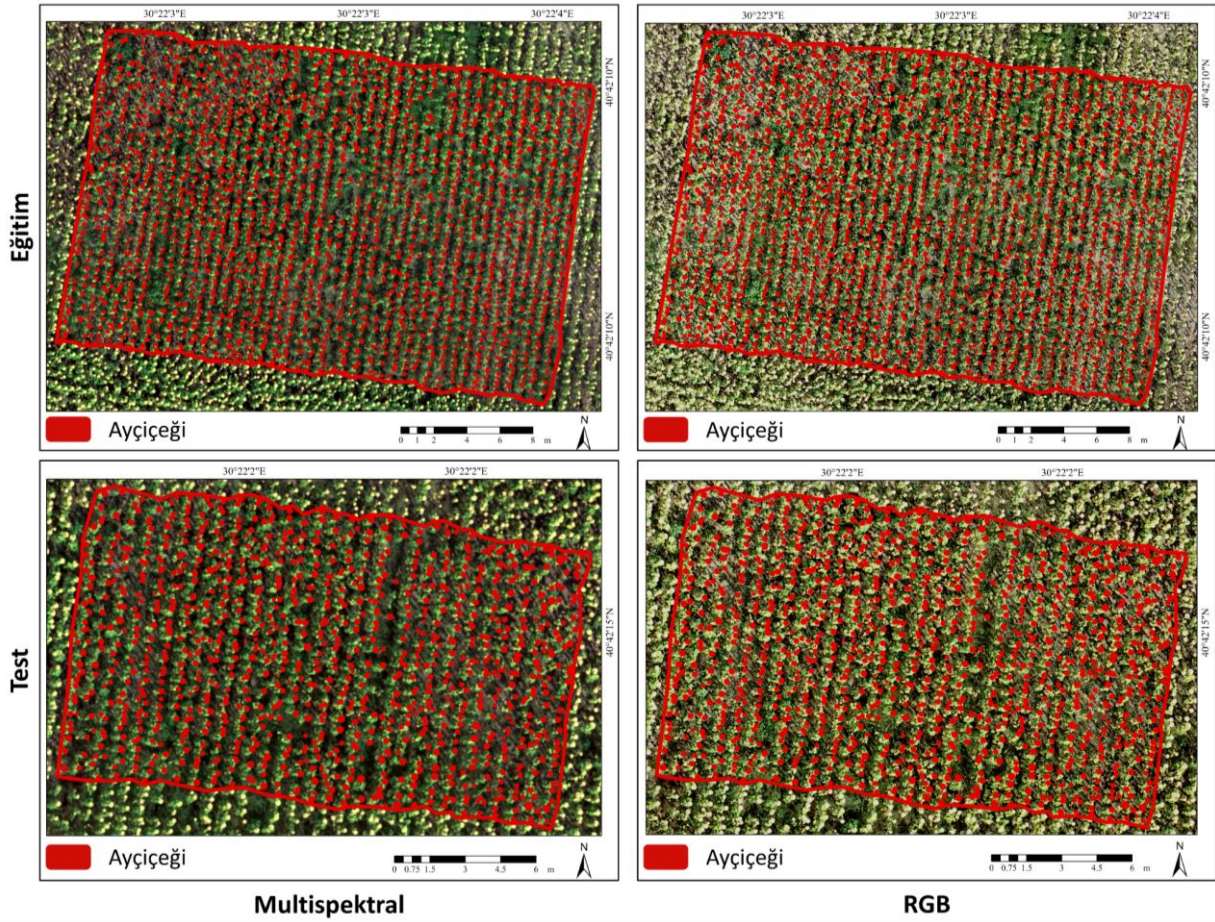
Multispektral İHA hava fotoğraflarının radyometrik kalibrasyonu MAPIR V2 kamera reflektans kalibrasyon paneli kullanılarak gerçekleştirilmiştir. Panel uçuşun hemen öncesinde çalışma alanına konumlandırılmış ve İHA kamerası ile fotoğraflanmıştır. Panelde beyaz, açık gri, koyu gri ve siyah olmak üzere dört temel hedef renk yer almakta olup bu hedeflere ilişkin reflektans değerleri distribütör firmadan sağlanmış ve hava fotoğraflarının radyometrik kalibrasyon işlemleri tamamlanmıştır. Geometrik yöneltme ve radyometrik kalibrasyon işlemlerinin tamamlanmasının ardından sırasıyla yoğun nokta bulutu, dijital yüzey modeli (DYM) ve ortomozaik üretimleri yüksek kalite parametreleri uygulanarak gerçekleştirilmiştir. RGB ve multispektral İHA ortomozaikleri sırasıyla 1,4 cm ve 2,6 cm YÖA'da elde edilmiştir (Şekil 3).



Şekil 3. Çalışma alanında üretilen ortomozaikler: (a) Multispektral, (b) RGB

3.2. Ayçiçeği Çiçek Tablası Veri Seti Oluşturma

Derin öğrenme tabanlı bireysel tarımsal ürün tespitinde hassas bir şekilde etiketlenmiş veri setinin oluşturulması model performansı açısından kritik öneme sahiptir. Model kurulumunda kullanılmak üzere ihtiyaç duyulan etiketli veri setinin oluşturulması amacıyla çalışma alanında üretilen RGB ve multispektral ortomozaikler üzerindeki ayçiçeği çiçek tablaları ArcGIS Pro 3.0.3 yazılımında görsel yorumlama ile manuel olarak "Ayçiçeği" sınıfı altında etiketlenmiştir. Bu bağlamda, her bir ortomozaik üzerinde ayrı ayrı olarak Şekil 4'te gösterilen eğitim bölgesi içerisinde 2.018, test bölgesi içerisinde ise 1.001 ayçiçeği örneği etiketlenmiştir. Eğitim bölgesinde etiketlenen örnekler Mask R-CNN modelinin eğitimi ve doğrulaması amacıyla, test bölgesinde etiketlenen örnekler ise eğitilen modelin tespit doğruluğunun detaylı olarak analiz edilmesinde kullanılmıştır. Çok yüksek çözünürlüklü İHA verilerinin işlenmesinin yoğun emek gerektiren zaman alıcı bir süreç olması ve evrimsel sinir ağlarının büyük veri setleriyle birlikte büyük hesaplama yükü gerektirmesi nedeniyle ortomozaik verilerin doğrudan model eğitiminde kullanılması uygun olmamaktadır (Yıldırım vd., 2024b). Bu sebeple GPU kısıtlamalarının önüne geçmek için ortomozaikler %50 bindirme (128×128 piksel) ile 256×256 piksel boyutunda görüntü parçalarına bölünmüştür. Görüntü bindirmesi eğitim örnek sayısını artırmak ve görüntü kenar bölgelerine denk gelen ayçiçekleri için sınır problemini önleyerek her örneğin en az bir görüntü parçası içerisine düşmesini sağlamak amacıyla kullanılmıştır. Ayrıca eğitim örneği sayısını artırmak ve model performansını iyileştirmek için eğitim veri setleri 90°, 180° ve 270° yönlerinde döndürülerek yapay veri artırımı işlemi gerçekleştirilmiştir. Sonuç olarak RGB eğitim veri seti toplamda 492 görüntü ve 24.912 örnek, multispektral eğitim veri seti ise 492 görüntü 24.852 örnek içermektedir. Ardından oluşturulan eğitim veri setleri modelin eğitimi ve doğrulaması için %80 ve %20 oranlarında rastgele olarak eğitim ve doğrulama veri setleri olarak ayrılmıştır.



Şekil 4. Multispektral ve RGB ortomozaikler üzerinde eğitim ve test bölgeleri için oluşturulan zemin gerçeği verileri

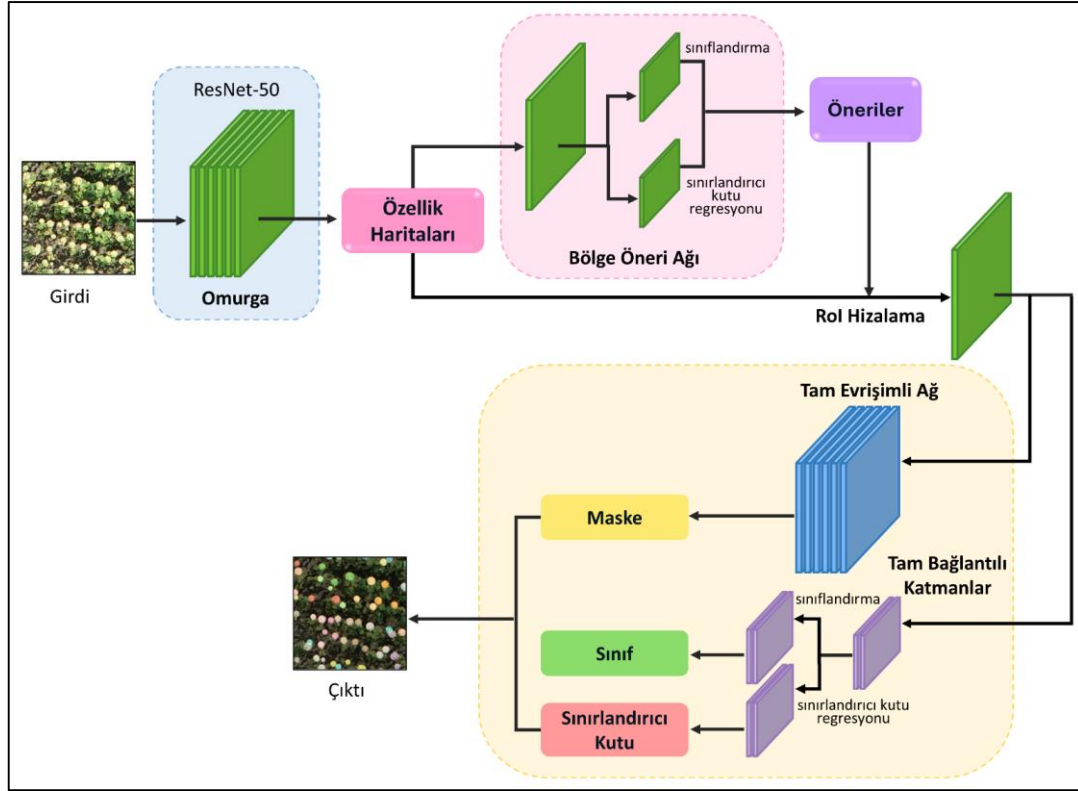
3.3. Mask R-CNN Model Eğitimi ve Performans Analizi

Derin öğrenme tabanlı iki aşamalı obje tespit yöntemi Faster R-CNN'in genişletilmiş bir versiyonu olan Mask R-CNN obje tespitini semantik segmentasyon ile birleştiren bir örnek segmentasyonu modelidir (He vd., 2017). Objeye tespiti görüntüdeki her bir nesnenin sınırlandırıcı kutu ile konumlandırıldığı ve bu nesnelerin sınıflandırıldığı bir problemdir. Semantik segmentasyon ise görüntüdeki her pikseli nesne örnekleri ayırt edilmeksizin belli bir dizi sınıf değerlerine sınıflandırmayı amaçlar. Bu bağlamda örnek segmentasyonu görüntüdeki nesnelere sınırlandırıcı kutu ile tespit eder ve eş zamanlı olarak her bir örneğin piksel bazlı segmentasyon maskesini oluşturur. Mask R-CNN çalışma prensibi olarak Faster R-CNN'e benzer iki aşamalı prosedürü esas almaktadır. İlk aşamada tüm görüntü taranır ve görüntüde nesne bulunan potansiyel alanlar için bölge önerileri oluşturulur. İkinci aşamada Faster R-CNN'de belirlenen bölgelerde sınırlandırıcı kutu regresyonu ve sınıflandırma işlemi ile tahmin edilen kutu ofsetleri ve sınıflara ek olarak Mask R-CNN'de her bölge için ikili segmentasyon maskeleri tahmin edilir.

Temel mimarisi Şekil 5'te sunulan Mask R-CNN üç ana bileşenden oluşur: (i) özellik çıkarıcı ağ, (ii) bölge öneri ağı, (iii) üç farklı fonksiyon dalı için tam bağlantılı katmanlar ve tam evrişimli ağ. Omurga ağı olarak bilinen özellik çıkarıcı ağ, girdi görüntüler üzerinde özellikler çıkarmak ve özellik haritaları oluşturmaktan sorumlu olan genel olarak bir evrişimli sinir ağıdır (örneğin, ResNet-50 ve FPN). Bölge öneri ağı (Region Proposal Network-RPN), oluşturulan özellik haritalarında nesnelerin bulunabileceği olası alanlar için bir dizi bölge önerisinde (Region of Interest-RoI) bulunur. Önerilen bölgeler sınıflandırma, sınırlandırıcı kutu regresyonu ve piksel bazında segmentasyon için tam evrişimli (Fully Connected-FC) katmanlara ve tam evrişimli ağa (Fully Convolutional Network-FCN) gönderilir. Modelin kayıp fonksiyonu sınıflandırma, konumlandırma ve maske kayıplarının kombinasyonundan oluşan bir çoklu görev kaybı fonksiyondur ve aşağıdaki şekilde tanımlanır:

$$L = L_{cls} + L_{box} + L_{mask} \quad (1)$$

Eşitlikte L_{cls} sınıflandırma kaybını, L_{box} sınırlandırıcı kutu kaybını ve L_{mask} segmentasyon kaybını temsil etmektedir.



Şekil 5. Mask R-CNN mimarisi

Mask R-CNN modelinin ayçiçeği çiçek tablası tespit performansını değerlendirmek için derin öğrenme tabanlı obje tespit çalışmalarında yaygın olarak kullanılan Hassasiyet (precision), Duyarlılık (recall), F1 Skor, IoU (birleşim üzerinde kesişim) ve mAP (genel ortalama hassasiyet) doğruluk metrikleri kullanılmıştır (Denklem 2-6). Bu metriklerin hesaplanmasında hata matrisi bileşenlerinden Doğru Pozitif (DP), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri kullanılmaktadır. Gerçekte ayçiçeği olan nesnelerin model tarafından da ayçiçeği olarak tahmin edildiği durumlar DP, gerçekte ayçiçeği olmayan nesnelerin model tarafından ayçiçeği olarak tahmin edildiği durumlar YP, gerçekte ayçiçeği olan ancak model tarafından tahmin edilmeyen ayçiçekleri YN olarak temsil edilir. IoU metriği model tarafından tahmin edilen ayçiçeklerinin ve zemin gerçeği ayçiçeklerinin kesişim alanının birleşim alanına bölünmesi ile hesaplanır. Diğer bir ifadeyle, IoU, bir modelin tahmin ettiği sınırlayıcı kutu veya segmentasyon maskesinin, yer doğrulama verisiyle ne kadar örtüştüğünü ölçen bir performans göstergesidir. Objeye tespiti ve örnek segmentasyonu çalışmalarında sıklıkla kullanılan IoU metriği genellikle derin öğrenme modellerinde tahmin edilen her bir bireysel nesnenin DP, YP ve YN olarak nitelendirilmesinde bir eşik değeri olarak kullanılır ve bu eşik değeri genellikle 0,5 olarak kabul edilir (Maxwell vd., 2021). IoU metriği için kullanılan bu eşik değeri, bir tahminin doğru kabul edilmesi için gereken minimum örtüşme miktarını belirler. Örneğin model tarafından doğru olarak tahmin edilen ve IoU değeri 0,6'dan büyük olan ayçiçekleri DP, model tarafından kaçırılan ve IoU değeri 0,6'dan küçük olan ayçiçekleri YN olarak dikkate alınır. Hassasiyet modelin tahmin ettiği toplam DP sayısının toplam tahmin sayısına bölünmesi ile hesaplanır. Duyarlılık ise modelin tahmin ettiği toplam DP sayısının toplam zemin gerçeği nesne sayısına bölümüdür. F1 Skor, Hassasiyet ve Duyarlılığın harmonik ortalaması olarak hesaplanan bir performans metriğidir. Derin öğrenme uygulamalarında Hassasiyet-Duyarlılık grafiği altında kalan alan AP (ortalama hassasiyet) metriği olarak ifade edilir (Padilla vd., 2021). AP değeri sınıf bazında ve her IoU değeri için ayrı ayrı olarak hesaplanır. mAP ise tüm sınıflar için ve çok sayıda IoU eşliğinde, genellikle 0,5 ile 0,95 arasında 0,05'lik artışla değişen 10 eşik değerinde, hesaplanan AP değerlerinin ortalamasıdır (Gibril vd., 2024).

$$\text{Hassasiyet} = \frac{DP}{DP+YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

$$\text{F1 Skor} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} = \frac{\text{Alan}(B_{\text{gerçek}} \cap B_{\text{tahmin}})}{\text{Alan}(B_{\text{gerçek}} \cup B_{\text{tahmin}})} \quad (5)$$

$$mAP = \left(\frac{1}{N}\right) \sum_{i=1}^N (AP)_i \quad (6)$$


4. Bulgular ve Tartışma

Ayçiçeği çiçek tablalarının tespiti için oluşturulan iki farklı veri seti ile Mask R-CNN modelinin eğitimi ve testi ArcGIS Pro yazılımı Python Uygulama Programlama Arayüzü (API) ve PyTorch derin öğrenme kütüphanesi kullanılarak gerçekleştirilmiştir. Tüm uygulamalarda Intel® Core™ i5-10200H işlemci, 8 GB RAM ve NVIDIA GeForce RTX 1650 Ti ekran kartına sahip bir bilgisayar kullanılmıştır. Mask R-CNN modeli, omurga ağı olarak ResNet-50 mimarisi kullanılarak transfer öğrenme yaklaşımı ile eğitilmiştir. ResNet-50 (Residual Network) (He vd., 2016) ImageNet veriseti üzerinde eğitilmiş 50 katmanlı bir evrimsel sinir ağı olup Mask R-CNN model eğitiminde hızı ve doğruluğu artırmak amacıyla omurga ağı olarak tercih edilmiştir. Öğrenme oranının optimum değerinin tespiti için otomatik öğrenme oranı bulucu (Smith, 2017) fonksiyonu kullanılmış ve modelin omurga ağının eski katmanlarının optimizasyonu için daha küçük bir öğrenme oranı ve ayçiçeği tespiti için yeni eklenen katmanların eğitilmesi için daha büyük bir öğrenme oranı belirlenmiştir. Model girdi boyutu orijinal görüntü boyutlarını korumak amacıyla 256×256 piksel olarak ayarlanmış, yüksek işlem yükü ve ekran kartı sınırlamaları nedeniyle yığın boyutu 2 olarak belirlenmiştir. RGB ve multispektral veri setleri ile ayrı ayrı oluşturulan Mask R-CNN modeli Tablo 1’de verilen hiperparametre kombinasyonları kullanılarak 50 epok boyunca eğitilmiştir.

Tablo 1. Mask R-CNN modeli hiperparametre konfigürasyonu

Hiperparametre	Değer	
	RGB	Multispektral
Omurga Ağı	ResNet-50	ResNet-50
Epok	50	50
Yığın Boyutu	2	2
Öğrenme Oranı (Omurga, Model)	(0,000016, 0,00016)	(0,000013, 0,00013)
Görüntü Boyutu	256×256	256×256

Model eğitim ve doğrulama sürecine ilişkin kayıp grafikleri Şekil 6’da verilmiştir. Her iki grafikten de görüleceği üzere eğitim ve doğrulama kaybı eğitim süresince azalmakta ve yaklaşık 40 epoktan sonra stabil hale gelmektedir. Eğitim kaybı ile doğrulama kaybının birlikte azalma eğilimi göstermesi modellerde aşırı öğrenmenin (overfitting) gözlemlenmediğini, modellerin eğitim veri setinde öğrendiklerini doğrulama veri seti üzerinde genellebildiğini ifade etmektedir. Öte yandan multispektral veri seti ile eğitilen modelin kayıp değerlerinin RGB veri setine göre daha çok yakınsadığı görülmektedir.



Şekil 6. Mask R-CNN modeli eğitim ve doğrulama kaybı

Eğitim sonucunda Mask R-CNN modeli RGB ve multispektral doğrulama veri setleri üzerinde 0,50 IoU eşik değerinde sırasıyla %78,25 ve %84,68 AP değerleri elde etmiştir. Modelin multispektral veri seti üzerinde yaklaşık %6'lık daha yüksek bir AP skoru ile üstün performans göstermesi ayçiçeği çiçek tablası tespitinde çok bantlı görüntülerin kullanılmasının model doğruluğunu arttırdığını göstermektedir. Modelin performansını daha detaylı analiz etmek için eğitilen modellerin test bölgesindeki genelleştirme yeteneği incelenmiştir. Ayçiçeği çiçek tablalarının tespiti için minimum tahmin eşik değeri 0,50 olarak ayarlanmıştır. Buna göre model belli bir güven skoru ile tahmin ettiği ayçiçeklerinden sadece %50'den daha yüksek güven skoruna sahip tahminleri çıktıya dahil etmektedir. Tahmin aşamasında test bölgesinden çıkarılan 256x256'lık piksel boyutlu görüntü parçalarını dört yığın boyutuyla işleme alan model için dolgu (padding) boyutu 64 piksel olarak ayarlanmıştır. Bu sayede model çıkarım sırasında birden fazla görüntü parçasına denk düşen görüntü kenarlarındaki kırılmış ayçiçeği örneklerinin bulunduğu bu bölgeleri sonuca dahil etmemektedir. Bu bölgelerdeki ayçiçekleri bindirmeli olarak bölünen görüntü parçalarından en az birinin içine düştüğü için bir sonraki görüntü parçasında tespit edilmektedir. Böylece modelin, görüntülerin dört bir kenarından 64 piksel içeri dolgu yapılarak sadece merkezi bu dolgulu bölgenin içine düşen nesnelere algılaması sağlanmıştır. Modelin aynı nesne için tahmin ettiği birden fazla çakışan maskelerin elimine edilmesi ve nihai tek bir çıktının elde edilebilmesi için Maksimum Olmayan Bastırma (Non-Maximum Suppression) algoritması uygulanmıştır. Buna göre maksimum bindirme oranı 0,25 olarak belirlenmiş ve böylece aynı nesne için tahmin edilen iki maske arasındaki bindirme oranı %25'ten büyükse o maskeler arasında düşük güven skoruna sahip olan silinerek nihai tespit sonucu elde edilmiştir.

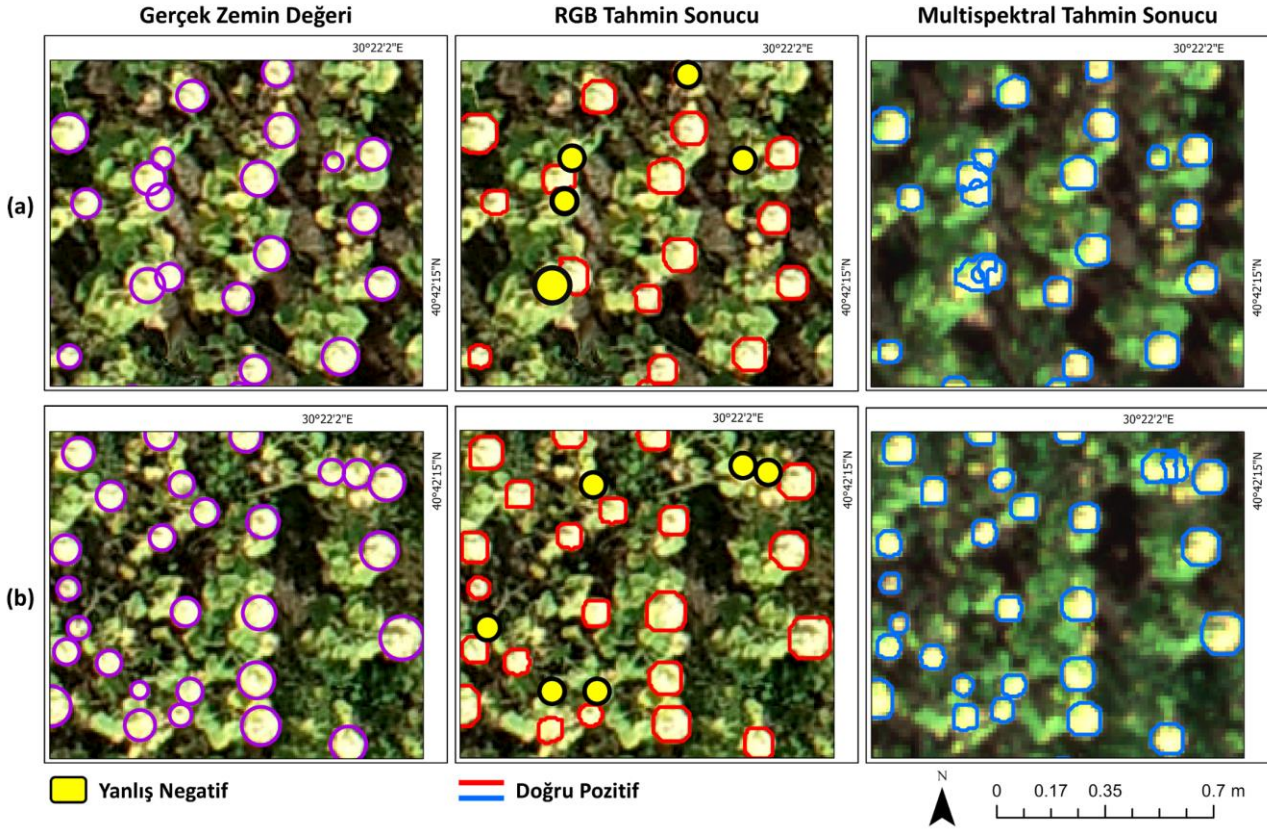
Mask R-CNN modelinin test bölgesindeki RGB ve multispektral veri setleri üzerinde ayçiçeği çiçek tablası tespit doğruluğu 0,50 ve 0,75 IoU eşik değerleri göz önüne alınarak hesaplanmış ve sonuçlar Tablo 2'de verilmiştir. Multispektral veri seti, beş bantlı (R, G, B, kırmızı-kenar (RE) ve yakın kızılötesi (NIR)) bir yapıya sahip olup konumsal çözünürlüğü yaklaşık 2,6 cm iken, RGB veri seti ise daha yüksek bir konumsal çözünürlüğe (yaklaşık 1,4 cm) sahiptir. IoU eşik değeri 0,50 olarak değerlendirildiğinde model multispektral veri seti üzerinde F1 Skor, AP metrikleri için sırasıyla %96,73 ve %94,74 değerlerini elde ederek RGB veri setinden daha üstün performans göstermiştir. Bu fark, multispektral verinin sunduğu spektral veri zenginliğinin, özellikle RE ve NIR gibi bitki ve vejetasyon özelliklerinin spektral olarak ayırt edilmesi noktasında önemli bilgiler sağlayan bantların modelin performansını artırmasıyla ilişkilidir. Spektral bantların bu katkısı, multispektral verinin daha düşük konumsal çözünürlüğüne rağmen doğruluğunun yüksek olmasını sağlamıştır. Diğer taraftan RGB veri setinde multispektrale göre yaklaşık üç kat daha fazla YN tespit edilmiştir. Bu durum, RGB veri setindeki spektral bilginin sınırlı olması nedeniyle modelin daha fazla ayçiçeği örneğini tespit edemediğini göstermektedir. Bununla birlikte, RGB veri setinin daha yüksek konumsal çözünürlüğü, segmentasyon maskelerinin sınırlarını daha net belirlemeye olanak sağlamakta ancak spektral verideki eksiklik, bu avantajı IoU \geq 0,50 durumunda yeterince dengeleyememektedir. Öte yandan IoU eşik değeri 0,75 olarak değerlendirildiğinde, RGB veri seti tüm metriklerde multispektral veriden daha yüksek doğruluk sağlamıştır. Örneğin, F1 Skoru RGB için %78,19 iken multispektral veri setinde %73,57 olarak hesaplanmıştır. Benzer şekilde, AP değeri RGB için %63,50, multispektral veri seti için ise %56,57 olarak bulunmuştur.

Tablo 2. RGB ve multispektral test veri setleri için 0,50 ve 0,75 IoU eşik değeri için hesaplanan doğruluk metrikleri

Eşik değer	Veri seti	Hassasiyet	Duyarlılık	F1 Skor	AP	DP	YP	YN
IoU \geq 0,50	RGB	<u>0,9810</u>	0,8791	0,9273	0,8746	880	17	121
	Multispektral	0,9785	<u>0,9560</u>	<u>0,9672</u>	<u>0,9474</u>	957	21	44
IoU \geq 0,75	RGB	<u>0,8272</u>	<u>0,7413</u>	<u>0,7819</u>	<u>0,6350</u>	742	155	259
	Multispektral	0,7444	0,7273	0,7357	0,5657	728	250	273

IoU metriği, modelin tahmin ettiği segmentasyon maskelerinin gerçek zemin değerleriyle örtüşüm oranını ölçen bir metrik olup, yüksek eşik değerleri modelin konumsal olarak daha hassas segmentasyonlar üretmeye zorlar. Bu bağlamda, RGB veri setinin konumsal çözünürlüğünün multispektral veri setinden daha yüksek olması, artan IoU eşik değerlerinde (IoU \geq 0,75) RGB veri setinin daha üstün performans göstermesine neden olmuştur. Bu sonuçlar modelin RGB veri seti üzerinde tahmin ettiği ayçiçeği maskelerinin multispektrale göre konumsal olarak daha doğru ve gerçek zemin değerine daha yakın olduğunu ortaya koymaktadır. Bu durum ise RGB veri setinin konumsal çözünürlüğünün yüksek olması ve görüntüde artan detaylar dolayısıyla ayçiçeği nesnelere konumsal olarak ayırt edilebilirliğinin artması ile ilişkilendirilmektedir. Multispektral verinin daha düşük konumsal çözünürlükte olması, bu eşik değerinde segmentasyon doğruluğunu olumsuz yönde etkilemiştir. Ancak, sağladığı spektral verideki zenginlik, özellikle düşük IoU eşik değerlerinde multispektral veriye avantaj sağlamaktadır.

Derin öğrenme tabanlı obje tespitinde sıklıkla karşılaşılan küçük nesne tespiti problemi göz önüne alındığında modelin RGB veride nispeten daha küçük boyutlu ayçiçeklerinin tespitinde problem yaşadığı görülmektedir. Öte yandan RGB veride tahmin edilemeyen örnekler multispektral veride tespit edilebilse bile hassas bir şekilde nesne sınırlandırması gerçekleştirilememiştir. Özellikle çok sayıda içe içe geçmiş ayçiçeği çiçek tablaları söz konusu olduğunda gerek görüntüdeki konumsal detayın yetersiz oluşu ve gerekse nesne sınırlarının belirgin olmayışı nedeniyle doğru nesne sınırları üretilmemiştir.



Şekil 8. Modelin test veri seti üzerindeki hatalı tespit sonuçları: (a) Örnek 1, (b) Örnek 2

5. Sonuçlar ve Öneriler

Üreme aşamasındaki ayçiçeğinin çiçek tablasının sayısı ve boyutu, tohum verimi ve kalitesini doğrudan etkilediğinden hassas ve otomatik bir şekilde tespiti ve sayımı hassas tarım uygulamaları için son derece önemlidir. Bu çalışmada ayçiçeği çiçek tablalarının İHA ortomozaiklerinden tespiti için derin öğrenme tabanlı örnek segmentasyonu modeli Mask R-CNN'nin performansı araştırılmıştır. Ayrıca RGB ve beş bantlı multispektral verilerin model doğruluğu üzerindeki etkisi irdelenmiştir. Literatürde İHA verilerinden ayçiçeğinin tespiti için çeşitli derin öğrenme tekniklerini kullanan çalışmalar gerçekleştirilmiştir (Jing vd., 2024; Song vd., 2023; Poleshenko vd., 2023). Genel olarak semantik segmentasyon ve obje tespit mimarilerinin kullanıldığı çalışmalarda tek tür veri kaynağı (RGB veya multispektral) kullanılarak model performansı karşılaştırılmasına odaklanılmıştır. Farklı İHA verilerinin konumsal ve spektral çözünürlüklerinin avantaj ve dezavantajlarının incelenmesi noktasında mevcut çalışmada detaylı analizler gerçekleştirilerek literatürdeki araştırma boşluğunun doldurulması amaçlanmıştır. Ayrıca ayçiçeği çiçek tablası tespiti bu çalışmada örnek segmentasyonu problemi olarak ele alınarak literatürde daha önce çalışılmamış Mask R-CNN modeli bu bağlamda ilk kez değerlendirilmiştir.

Deneysel bulgulara göre Mask R-CNN modeli multispektral doğrulama veri setinde 0,50 IoU eşik değerinde %84,68 AP ile RGB veri setinden %6,43 daha yüksek doğruluk elde etmiştir. Eğitilen model ile test veri seti üzerinde yapılan detaylı doğruluk analizi sonuçlarına göre model 0,50 IoU eşik değerinde multispektral veri setinde %96,72 F1 Skor ve %94,74 AP ile daha üstün performans göstermiştir. Öte yandan 0,75 IoU eşik değerinde model RGB veri setinde %78,19 F1 Skor ve %63,50 AP değerlerine ulaşarak multispektral veriden daha yüksek doğruluk elde etmiştir. Bu durum iki ortomozaik arasındaki konumsal ve spektral çözünürlük farklılıkları ile açıklanabilmektedir.

Multispektral ortomozaikte RGB bantlara ek olarak kırmızı-kenar ve yakın kızın ötesi bantlar bulunmakta olup multispektral veri ile eğitilen model ayçiçeği çiçek tablalarının spektral karakteristiği hakkında daha detaylı bilgi öğrenebilmektedir. Buna karşın RGB ortomozaikte yaklaşık 1,4 cm olan konumsal çözünürlük multispektral ortomozaikte yaklaşık 2,7 cm'ye düşmekte ve ayçiçeği detay seviyesinde yaşanan kayıp modelin konumlandırma performansını önemli ölçüde etkilemektedir. Derin öğrenme tabanlı obje tespit çalışmalarında doğruluk analizinde genel olarak temel alınan 0,50 IoU eşik değerine göre çalışmada multispektral veri setinin daha yüksek doğruluk elde etmesi spektral çözünürlüğün yüksek olması ile ilişkilendirilmektedir. Ancak artan IoU eşik değerlerinde modelin konumsal olarak daha hassas tahminleri doğru olarak nitelendirildiği için RGB veri setinde daha yüksek performans göstermesi verinin konumsal çözünürlüğüne dayanmaktadır. Dolayısıyla mevcut çalışma bulgularına göre ayçiçeği çiçek tablasının konum bilgisinin ön planda olduğu çalışmalarda RGB verilerin kullanılmasının, verim tahmini gibi ürün sayısı ile doğrudan ilişkili uygulamalarda ise multispektral verilerin kullanılmasının daha faydalı olacağı sonucuna ulaşılmaktadır.

Bu bulgular İHA verilerinden tarımsal ürünlerin tespiti kapsamında literatürde gerçekleştirilen benzer çalışmalar tarafından da desteklenmektedir. Örneğin, Zheng vd. (2020) İHA görüntülerinden pirinç bitkilerini tespit etmek için karar ağacı tabanlı bir metodoloji uygulamış ve RGB, NIR ve multispektral veriler için genel sınıflandırma doğruluklarını sırasıyla %91,25, %92,88 ve %93,53 olarak elde etmiştir. Çalışmada kullanılan RGB, NIR ve multispektral görüntülerin yer örneklemeye aralıklarının 1,3 cm, 1,4 cm ve 5,4 cm olduğu göz önüne alındığında multispektral verinin düşük konumsal çözünürlüğüne rağmen üstün performans göstermesi çalışma bulgularının mevcut çalışma ile tutarlılık gösterdiğini ortaya koymaktadır. Benzer şekilde Jurišić vd. (2022) tarafından yapılan bir diğer çalışmada İHA görüntülerinden rastgele orman yöntemiyle mısır bitkisinin sınıflandırılmasında en yüksek genel doğruluk değeri RE, NIR ve NDVI kombinasyonunda elde edilirken bunu multispektral ve RGB veri setleri takip etmiştir. Öte yandan Mask R-CNN modeli ile gerçekleştirilen çalışmalara bakıldığında Gao vd. (2023) RGB İHA görüntülerinden Mask R-CNN ile mısır fidelerinin tespitinde konumsal çözünürlüğün etkisini incelemiş ve 30 m, 40 m, 50 m uçuş irtifasında 0,50 IoU eşik değerindeki AP değerlerini sırasıyla %88,7, %87,5, %85,2 olarak elde etmiştir. Konumsal çözünürlüğün 30 m uçuş irtifası için 0,8 cm, 40 m için 1,1 cm ve 50 m için 1,4 cm olduğu göz önüne alındığında uçuş yüksekliğinin azalması ve dolayısıyla konumsal çözünürlüğün artmasıyla model performansının da arttığı görülmüştür. Kozalaklı ağaç fidanlarının tespitinde Fromm vd. (2019) 0,3 cm, 1,5 cm, 2,7 cm ve 6,3 cm konumsal çözünürlüğe sahip RGB İHA görüntülerinden Mask R-CNN modeli ile en yüksek performansı (mAP@0,50=%81) 0,3 cm konumsal çözünürlüğünde elde etmiştir.

Ayrıca çalışma bulgularını etkileyebilecek bir diğer husus ise model eğitiminde kullanılan hiperparametrelerin optimizasyonudur. Çalışmada model eğitiminde donanım kapasitesine uygun olarak en iyi performans gösteren parametreler seçilmiştir. Bu bağlamda model ResNet-50 omurga ağıyla 2 yığın boyutuyla eğitilmiştir. Ancak yüksek donanım kapasitesinin mevcut olması durumunda daha derin bir omurga ağının (ResNet-101 ResNet-152, Inception ResNet vb.) kullanılması hesaplama yükü ile birlikte model performansı da artırabilmektedir. Örneğin, erken aşamada otların RGB İHA görüntülerinden tespiti için Qureshi vd. (2023) tarafından yapılan çalışmada ResNet-50, ResNet-101, ResNeXt-101 omurga ağları ile eğitilen Mask R-CNN modelinin en yüksek doğruluğa 89 milyon parametre ile en kompleks yapıya sahip ResNeXt-101 omurga ağı ile ulaştığı görülmüştür. Bunu %1 farkla 45 milyon parametreye sahip ResNet-101 ağı ve devamında 26 milyon parametreye sahip ResNet-50 ağı takip ederek omurga ağ karmaşıklığı azaldıkça model doğruluğunun da düştüğü gözlemlenmiştir. Bu doğrultuda hiperparametre konfigürasyonunun derin öğrenme modellerinin doğruluğu ve hızı üzerinde önemli bir etkiye sahip olduğu ve mevcut çalışma sonuçlarının daha yüksek başarılı hiperparametreler kullanılarak iyileştirilebileceği de vurgulanmalıdır (Yıldırım & Kavzoglu, 2025).

Genel olarak çalışmanın sonuçları Mask R-CNN modeli ve İHA verilerinin ayçiçeği tespiti ve sayımında hassas ve güvenilir birer araç olarak kullanılabilirliğini vurgulamaktadır. Ayçiçeği tespiti ile ayçiçeği yoğunluğunun belirlenmesi hasat öncesi dönemde verim tahmini konusunda önemli bir veri kaynağıdır. Belirli bir bölgedeki ayçiçeği tespiti ve sayımı özellikle çiftçilere ve uygulayıcılara bireysel ayçiçeğinin büyüme durumu ve fenolojik aşamalarının belirlenmesi noktasında yardımcı olur. Dolayısıyla tarım uygulayıcıları ayçiçeğinin yetiştirme sürecine uygun tarımsal strateji ve politikalar uygulayabilirler. Bu noktada endüstrilerin sulama ve tozlaşma stratejilerini uygun zamanda, miktarda ve yöntemle ayarlamasına yardımcı olacak veriler sağlayarak tohum verimini ve kalitesini artırır.

Çalışmada derin öğrenme teknikleri ve İHA verilerinin hassas tarım uygulamaları kapsamında tarımsal ürünlerin tespitindeki performansı incelenmiş ve özellikle ayçiçeği özelinde literatürde sınırlı sayıda bulunan çalışmalara bir örnek teşkil ederek katkı sağlanmış olsa da halen geliştirilmesi gereken ve gelecek çalışmalarda gerçekleştirilmesi planlanan bazı noktalar bulunmaktadır. Bunlardan ilki derin öğrenme modelinin eğitiminde veri seti olarak İHA yükseklik verilerinin (Sayısal Yükseklik Modeli, Kanopi Yükseklik Modeli vb.) ve NDVI gibi çeşitli vejetasyon indekslerinin ve bunların çeşitli kombinasyonlarının kullanılması ve model performansı üzerine etkilerinin incelenmesi gerekmektedir. Bir diğeri modelin genelleştirilebilirliğinin testi için farklı bir bölgeden alınan ayçiçeği tarlası görüntüsü üzerinde model performansı incelenmelidir. Ürün gelişiminin takibi ve izlenmesi noktasında çalışmada incelenen üreme aşamasına ek olarak farklı fenolojik evrelerde ayçiçeğinin tespit edilebilirliği incelenebilir ve elde edilen sonuçlar ile ürün verim ilişkisi kurulabilir. Model tahminlerinin yorumlanabilmesi için Grad-CAM gibi açıklanabilir yapay zekâ tekniklerinden faydalanılmalı ve bu doğrultuda model performansı iyileştirilmelidir.

Son yıllarda transformatör tabanlı mimarilerin kullandıkları dikkat mekanizmaları sayesinde görüntüdeki küresel bağımlılıkları ve bağlamsal bilgileri kolayca yakalama yetenekleri tarımsal uygulamalarda potansiyel kullanım alanlarını artırmıştır. Dolayısıyla, ileriki çalışmalar obje tespiti ve sınıflandırmada popüler olarak kullanılan DETR gibi Transformatör tabanlı modellerin ayıççeği tablalarının tespiti noktasındaki performansının incelenmesine odaklanacaktır.

Kaynaklar

- Albahar, M. (2023). A survey on deep learning and its impact on agriculture: Challenges and opportunities. *Agriculture*, 13(3), Article 540. <https://doi.org/10.3390/agriculture13030540>
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481–2495.
- Bakhsipour, A., Sanaeifar, A., Payman, S. H., & de la Guardia, M. (2018). Evaluation of data mining strategies for classification of black tea based on image-based features. *Food Analytical Methods*, 11, 1041–1050.
- Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2022). Deep learning techniques to classify agricultural crops through UAV imagery: A review. *Neural Computing and Applications*, 34(12), 9511–9536.
- Centorame, L., Gasperini, T., Ilari, A., Del Gatto, A., & Foppa Pedretti, E. (2024b). An overview of machine learning applications on plant phenotyping, with a focus on sunflower. *Agronomy*, 14(4), Article 719. <https://doi.org/10.3390/agronomy14040719>
- Centorame, L., Ilari, A., Del Gatto, A., & Pedretti, E. F. (2024a). A systematic review on precision agriculture applied to sunflowers, the role of hyperspectral imaging. *Computers and Electronics in Agriculture*, 222, Article 109097. <https://doi.org/10.1016/j.compag.2024.109097>
- Ding, R., Luo, J., Wang, C., Yu, L., Yang, J., Wang, M., Zhong, S., & Gu, R. (2023). Identifying and mapping individual medicinal plant *Lamiophlomis rotata* at high elevations by using unmanned aerial vehicles and deep learning. *Plant Methods*, 19, Article 38. <https://doi.org/10.1186/s13007-023-01015-z>
- Food and Agriculture Organization. (2022). *Crops and livestock products*. <https://www.fao.org/faostat/en/#data/QCL>
- Fromm, M., Schubert, M., Castilla, G., Linke, J., & McDermid, G. (2019). Automated detection of conifer seedlings in drone imagery using convolutional neural networks. *Remote Sensing*, 11(21), Article 2585. <https://doi.org/10.3390/rs11212585>
- Gao, X., Zan, X., Yang, S., Zhang, R., Chen, S., Zhang, X., Liu, Z., Ma, Y., Zhao, Y., & Li, S. (2023). Maize seedling information extraction from UAV images based on semi-automatic sample generation and Mask R-CNN model. *European Journal of Agronomy*, 147, Article 126845. <https://doi.org/10.1016/j.eja.2023.126845>
- Gao, Z., Luo, Z., Zhang, W., Lv, Z., & Xu, Y. (2020). Deep learning application in plant stress imaging: A review. *AgriEngineering*, 2(3), Article 29. <https://doi.org/10.3390/agriengineering2030029>
- Gibril, M. B. A., Shafri, H. Z. M., Shanableh, A., Al-Ruzouq, R., bin Hashim, S. J., Wayayok, A., & Sachit, M. S. (2024). Large-scale assessment of date palm plantations based on UAV remote sensing and multiscale vision transformer. *Remote Sensing Applications: Society and Environment*, 34, Article 101195. <https://doi.org/10.1016/j.rsase.2024.101195>
- Guo, A., Huang, W., Dong, Y., Ye, H., Ma, H., Liu, B., Wu, W., Ren, Y., Ruan, C., & Geng, Y. (2021). Wheat yellow rust detection using UAV-based hyperspectral technology. *Remote Sensing*, 13(1), Article 123. <https://doi.org/10.3390/rs13010123>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016, June 27–30). *Deep residual learning for image recognition* [Conference presentation]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017, October 22–29). *Mask R-CNN* [Conference presentation]. IEEE International Conference on Computer Vision, Venice, Italy.
- Huang, Y., Reddy, K. N., Fletcher, R. S., & Pennington, D. (2018). UAV low-altitude remote sensing for precision weed management. *Weed Technology*, 32(1), 2–6. <https://doi.org/10.1017/wet.2017.89>
- International Society of Precision Agriculture. (2024). *Precision agriculture definition*. <https://www.ispag.org/about/definition>
- Jing, R., Niu, Q., Tian, Y., Zhang, H., Zhao, Q., Li, Z., Zhou, X., & Li, D. (2024). Sunflower-YOLO: Detection of sunflower capitula in UAV remote sensing images. *European Journal of Agronomy*, 160, Article 127332. <https://doi.org/10.1016/j.eja.2024.127332>
- Jurišić, M., Radočaj, D., Plaščak, I., Galić Subašić, D., & Petrović, D. (2022). The evaluation of the RGB and multispectral camera on the unmanned aerial vehicle (UAV) for the machine learning classification of maize. *Poljoprivreda*, 28(2), 74–80. <https://doi.org/10.18047/poljo.28.2.10>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Karami, A., Quijano, K., & Crawford, M. (2021). Advancing tassel detection and counting: Annotation and algorithms. *Remote Sensing*, 13(15), Article 2881. <https://doi.org/10.3390/rs13152881>

- Kerkech, M., Hafiane, A., & Canals, R. (2018). Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and Electronics in Agriculture*, 155, 237–243.
- Li, J., Li, Y., Qiao, J., Li, L., Wang, X., Yao, J., & Liao, G. (2023). Automatic counting of rapeseed inflorescences using deep learning method and UAV RGB imagery. *Frontiers in Plant Science*, 14, Article 1101143. <https://doi.org/10.3389/fpls.2023.1101143>
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review. *Remote Sensing*, 13(13), Article 2450. <https://doi.org/10.3390/rs13132450>
- Padilla, R., Passos, W. L., Dias, T. L., Netto, S. L., & Da Silva, E. A. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), Article 279. <https://doi.org/10.3390/electronics10030279>
- Poleshchenko, D., Mikhailov, I., & Petrov, V. (2023, March 29–31). *On the segmentation of sunflower plants in UAV photos* [Conference presentation]. 2023 25th International Conference on Digital Signal Processing and its Applications (DSPA 2023), Moscow, Russian Federation.
- Popescu, D., Stoican, F., Stamatescu, G., Ichim, L., & Dragana, C. (2020). Advanced UAV–WSN system for intelligent monitoring in precision agriculture. *Sensors*, 20(3), Article 817. <https://doi.org/10.3390/s20030817>
- Qureshi, S., Ameer, A., Zia, A., Latif, A., & Karrila, S. (2023). *Comparing the effectiveness of classic Mask RCNN and vision transformer in early weed detection*. SSRN. <http://dx.doi.org/10.2139/ssrn.4436132>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016, June 27-30). *You only look once: Unified, real-time object detection* [Conference presentation]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA.
- Sanaeifar, A., Guindo, M. L., Bakhshipour, A., Fazayeli, H., Li, X., & Yang, C. (2023). Advancing precision agriculture: The potential of deep learning for cereal plant head detection. *Computers and Electronics in Agriculture*, 209, Article 107875. <https://doi.org/10.1016/j.compag.2023.107875>
- Schneiter, A. A., & Miller, J. F. (1981). Description of sunflower growth stages. *Crop Science*, 21(6), 901–903.
- Sefercik, U. G., Nazar, M., Aydın, I., Büyüksalih, G., Gazioglu, C., & Bayirhan, I. (2024). Comparative analyses for determining shallow water bathymetry potential of multispectral UAVs: Case study in Tavşan Island, Sea of Marmara. *Frontiers in Marine Science*, 11, Article 1388704. <https://doi.org/10.3389/fmars.2024.1388704>
- Seiler, G. J. (1997). Anatomy and morphology of sunflower. In A. A. Schneiter (Ed.), *Sunflower technology and production* (pp. 67–111). American Society of Agronomy, Crop Science Society of America, Soil Science Society of America.
- Singh, P., Pandey, P. C., Petropoulos, G. P., Pavlides, A., Srivastava, P. K., Koutsias, N., Deng, K. A. K., & Bao, Y. (2020). Hyperspectral remote sensing in precision agriculture: Present status, challenges, and future trends. In P. C. Pandey, P. K. Srivastava, H. Balzter, B. Bhattacharya, & G. P. Petropoulos (Eds.), *Hyperspectral remote sensing* (pp. 121–146). Elsevier.
- Smith, L. N. (2017, March 24–31). *Cyclical learning rates for training neural networks* [Conference presentation]. 2017 IEEE Winter Conference on Applications of Computer Vision (WACV), Santa Rosa, CA, USA.
- Song, Z., Wang, P., Zhang, Z., Yang, S., & Ning, J. (2023). Recognition of sunflower growth period based on deep learning from UAV remote sensing images. *Precision Agriculture*, 24(4), 1417–1438.
- T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2024). *Sakarya İli 2023 Yılı Çevre Durum Raporu*. <https://webdosya.csb.gov.tr/db/ced/icerikler/sakarya-ilcdr-2023-1-20240614095821.pdf>
- T.C. Tarım ve Orman Bakanlığı. (2007). *Ayçiçeği tarımı*. <https://arastirma.tarimorman.gov.tr/etae/Belgeler/EgitimBrosur/2482012115736884.pdf>
- Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü. (2023). *2023 durum tahmin raporları*. <https://arastirma.tarimorman.gov.tr/tepege/Belgeler/PDF%20Durum-Tahmin%20Raporları/2023%20Durum-Tahmin%20Raporları/Ayçiçeği%20Durum-Tahmin%20Raporu%202023-392%20TEPGE.pdf>
- Türkiye İstatistik Kurumu. (2023). *Merkezi dağıtım sistemi*. <https://biruni.tuik.gov.tr/medas/?locale=tr>
- Xiao, J., Aggarwal, A. K., Rage, U. K., Katiyar, V., & Avtar, R. (2023). Deep learning-based spatiotemporal fusion of unmanned aerial vehicle and satellite reflectance images for crop monitoring. *IEEE Access*, 11, 85600–85614.
- Yang, Q., Shi, L., Han, J., Zha, Y., & Zhu, P. (2019). Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Research*, 235, 142–153.
- Yang, X., Ye, Y., Li, X., Lau, R. Y., Zhang, X., & Huang, X. (2018). Hyperspectral image classification with deep learning models. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5408–5423.
- Yıldırım, E., & Kavzoglu, T. (2025). Deep convolutional neural networks for ship detection using refined DOTA and TGRS-HRRSD high-resolution image datasets. *Advances in Space Research*, 75(2), 1871–1887. <https://doi.org/10.1016/j.asr.2024.10.028>

- Yıldırım, E., Colkesen, İ., & Sefercik, U. G. (2024a, July 9–10). *Identification of sunflowers (Helianthus annuus L.) from multi-temporal UAV orthomosaics using deep learning models* [Conference presentation]. 9th Advanced Engineering Days, Tabriz, Iran.
- Yıldırım, E., Sefercik, U. G., & Kavzoglu, T. (2024b). Automated identification of vehicles in very high-resolution UAV orthomosaics using YOLOv7 deep learning model. *Turkish Journal of Electrical Engineering and Computer Sciences*, 32(1), 144–165. <https://doi.org/10.55730/1300-0632.4060>
- Zheng, H., Zhou, X., He, J., Yao, X., Cheng, T., Zhu, Y., Cao, W., & Tian, Y. (2020). Early season detection of rice plants using RGB, NIR-G-B and multispectral images from unmanned aerial vehicle (UAV). *Computers and Electronics in Agriculture*, 169, Article 105223. <https://doi.org/10.1016/j.compag.2020.105223>

Kentsel Alanlarda 3B Gölge Analizi: Artvin Çoruh Üniversitesi Örneği

3D Shadow Analysis in Urban Areas: Artvin Coruh University Example

Ziya Usta^{1*} 

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ziya Usta
ziyausta@artvin.edu.tr

doi: 10.48123/rsgis.1602829

Yayın süreci

Geliş tarihi: 16.12.2024
Kabul tarihi: 14.03.2025
Basım tarihi: 26.03.2025

Özet

Kentsel alanlarda binaların oluşturduğu gölge etkisi özellikle güneş paneli kurulumu gibi uygulamalarda, kentsel iklim ve enerji verimliliği optimizasyonunda kritik bir role sahiptir. Geleneksel 2B analizlerin yetersizliği nedeniyle 3B gölge analizleri, binaların birbirine gölge oluşturma durumunun daha doğru tahmin edilmesini sağlar. Literatürde genellikle 2.5B modeller kullanılarak gölge analizleri yapılmıştır. Ancak bu modeller dikey yüzeylerin etkisini göz ardı etmektedir. Bu çalışmada 3B modeller kullanarak 3B gölge analizi yapılmıştır. 3B modelleme için prosedürel modelleme yöntemi kullanılmış, kat sayıları baz alınarak binalar LOD1 düzeyinde modellenmiştir. Işın İzleme (Ray-Tracing) algoritmasıyla güneşin günlük ve saatlik konumları dikkate alınarak gölge analizleri yapılmıştır. Artvin Çoruh Üniversitesi Seyitler ve Merkez Yerleşkelerinde binalar arası gölge etkisi düşük bulunmuştur. Ancak yakın mesafedeki yüksek binalar gölgeleme etkisi yaratmaktadır. Çatılardan sonra özellikle güney cephelerinin anlamlı düzeyde güneş ışığı aldığı belirlenmiş olup, bu da dış cephelerin de güneş paneli kurulum potansiyeli olduğunu ortaya koymaktadır. Bu çalışma, 3B gölge analizinin kentsel planlama süreçlerinde önemli bir araç olduğunu göstermektedir. Çalışmada elde edilen diğer önemli bir sonuç, analizlerin sadece çatıları değil dış cepheleri de kapsamı gerektiğidir. Bu sayede bina yüzeylerinden maksimum oranda yararlanılarak sürdürülebilir kentsel gelişim ve doğru yer seçimi sağlanabilir.

Anahtar kelimeler: 3B CBS, Gölge analizi, Konumsal analiz, Kentsel analitik

Abstract

The shadow effect created by buildings in urban areas plays a critical role in applications such as solar panel installation, urban microclimate, and energy efficiency optimization. Due to the inadequacy of traditional 2D analyses, 3D shadow analyses provide a more accurate prediction of the shading interactions between buildings. In the literature, shadow analyses have generally been conducted using 2.5D models. However, these models neglect the effects of vertical surfaces. In this study, a 3D shadow analysis was conducted using 3D models. Procedural modeling was employed for 3D modeling, and buildings were modeled at the LOD1 level based on the number of floors. Shadow analyses were performed using the Ray-Tracing algorithm, considering the daily and hourly positions of the sun. The shadow effect between buildings in Artvin Çoruh University Seyitler Campus and Center Campus was found to be low. However, high-rise buildings in close proximity create a significant shading effect. It was determined that, in addition to rooftops, southern facades receive a significant amount of sunlight, revealing the potential for solar panel installation on building facades as well. This study demonstrates that 3D shadow analysis is an important tool in urban planning processes. Another key finding is that analyses should not be limited to rooftops but should also include building facades. This approach ensures the maximum utilization of building surfaces, facilitating sustainable urban development and optimal site selection.

Keywords: 3D GIS, Shadow analysis, Spatial analysis, Urban analytics

1. Giriş

Kentsel analizlerde 3B gölge analizi uygulamaları, şehirlerin büyümesi ve gelişmesiyle birlikte giderek daha önemli hale gelmiştir. Bina ve diğer yapılar ile doğal ışık arasındaki etkileşimi anlamak için daha sofistike yöntemler gerektiren 3B gölge analizi, binalar ve diğer yapıların oluşturduğu gölgelerin güneş enerjisi potansiyeli, yaya hareketi ve genel kentsel yaşanabilirlik gibi çeşitli dinamiklere etkisini değerlendirmek için üç boyutlu modellerden yararlanır. 3B gölge analizi sayesinde, şehir plancıları ve araştırmacılar, gölgelerin mekânsal dağılımına dair önemli bilgiler edinebilir ve bu da arazi kullanımını optimize etmek ve kentsel alanların sürdürülebilirliğini artırmak için kritik bir rol oynar. Artan kentleşme ve binaların karmaşık geometrileri göz önüne alındığında, geleneksel 2D analizler, güneş enerjisi kurulumlarının verimliliğini önemli ölçüde azaltabilecek gölgeleme etkilerini doğru bir şekilde tahmin etmekte genellikle yetersiz kalmaktadır (El-Hosaini, 2015; Alam vd., 2012). Özellikle binaların diğer binalar üzerinde oluşturduğu gölge etkisinin modellenmesi 2B veriler ile mümkün olmamaktadır. 3B modeller kullanılarak, araştırmacılar güneş ışığı ile kentsel peyzaj arasındaki dinamik etkileşimleri simüle edebilir ve potansiyel güneş enerjisi üretimini daha hassas bir şekilde değerlendirebilir.

Gölgeleme, fotovoltaiik (PV) sistemlerin aldığı güneş ışınımını önemli ölçüde azaltarak enerji üretiminin düşmesine neden olabilir. Çevredeki yapıların oluşturduğu gölgeleri doğru bir şekilde modellenerek, güneş enerjisi kurulumları için en uygun yerleri belirlenebilir, böylece enerji üretimi maksimize edilerek güneş enerjisine dayalı projelerinin ekonomik uygulanabilirliği artırılabilir (Alam vd., 2012; Ninsawat & Hossain, 2016). Bu durum, özellikle sınırlı çatı alanına sahip ve komşu binaların gölgeleme potansiyelinin yüksek olduğu yoğun nüfuslu bölgelerde büyük önem taşır (Vo & Laefer, 2019). Ayrıca, 3B gölge analizi, kentsel iklimi daha iyi anlamaya katkı sağlar. Gölgeleme, şehirlerdeki sıcaklık değişimlerini ve rüzgâr desenlerini etkileyerek enerji tüketimi ve sakinlerin konfor düzeyleri üzerinde rol oynar. Gölge dinamiklerini analiz ederek, şehir plancıları daha etkili yeşil alanlar tasarlayabilir ve doğal havalandırmayı optimize ederek ısı adalarını azaltabilir (El-Hosaini, 2015). Bu bütüncül kentsel tasarım yaklaşımı, yalnızca yaşam kalitesini artırmakla kalmaz, aynı zamanda enerji verimli bina uygulamalarını teşvik ederek çevresel sürdürülebilirliği destekler.

3B gölge analizinin kentsel planlama süreçlerine entegrasyonu, imar düzenlemeleri ve arazi kullanım politikalarına ilişkin daha bilinçli kararların alınmasını kolaylaştırabilir. Şehirler genişlemeye devam ederken, gölgelemenin kamusal alanlar ve yerleşim bölgeleri üzerindeki etkilerinin anlaşılması, kentsel yaşanabilirliği korumak açısından kritik bir önem taşır. Gölge etkilerini görselleştirerek, plancılar tüm sakinlerin ihtiyaçlarını göz önünde bulunduran daha adil ve işlevsel kentsel ortamlar oluşturabilir (El-Hosaini, 2015; Zhou & Gorte, 2017).

Önemine rağmen 3B gölge analizi literatürde detaylı bir şekilde incelenmemiş, yapılan analizlerin çoğunda 2.5B sayısal yüzey modelleri kullanılmıştır. Bu çalışmanın amacı, Artvin Çoruh Üniversitesi kampüsünün 3B gölge analizini gerçekleştirerek binaların gölge etkileri ve güneş ışığı potansiyellerinin belirlenmesidir. Böylece gölge analizinin 3B olarak yapıldığı Türkiye'deki ilk çalışma olacak ve aynı zamanda Artvin ili için de bir ilk teşkil edecektir.

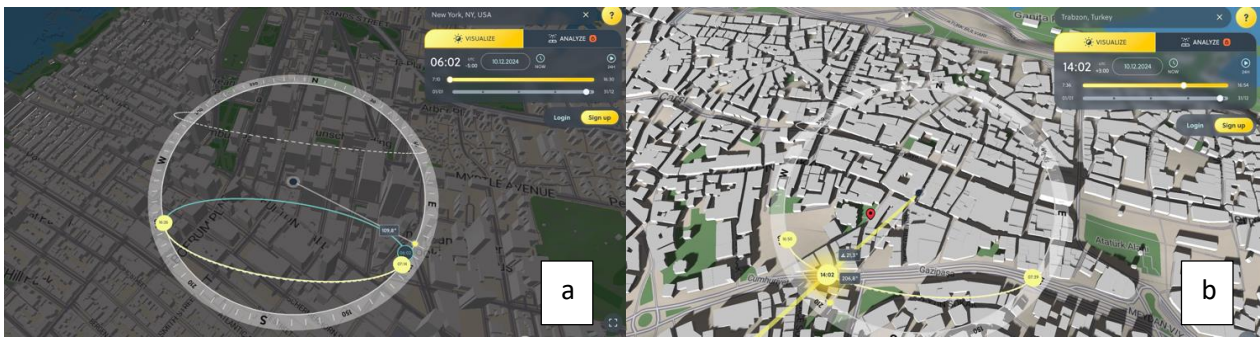
2. Literatür Özeti

Binalar nedeniyle oluşan gölgelerin tahmin edilmesi, kentsel planlama süreçlerinde yaygın bir şekilde kullanılmaktadır. Bu analizler, planlanan bir yapının çevresine olan etkilerinin değerlendirilmesi için uygulanır. Bazı belediyeler tarafından yasal olarak da zorunlu tutulmaktadır. Örneğin, Hollanda'da Lahey ve Kanada'da Mississauga gibi şehirlerde bu tür analizler gereklidir (Biljecki vd., 2015). Şenol (2022), gölge etkisi analizi kullanarak kentleşmenin yeşil alanlar üzerindeki etkisini araştırmış ve binaların bitki örtüsü üzerindeki gölgeleme etkilerinin değerlendirilmesinde CBS'nin nasıl kullanılabileceğini göstermiştir. Bu araştırma, gölge analizinin, güneş enerjisinin ötesine geçen daha geniş etkilerine dikkat çekerek, kentsel biyolojik çeşitliliğin ve yeşil altyapının korunmasındaki önemini vurgulamıştır. Diğer taraftan gölgelerin tahmini binaların güneş enerjisi potansiyelini tahmin etmek için de kritik bir öneme sahiptir, çünkü gölgeler, güneş panellerinin verimini dramatik şekilde düşürmektedirler. Bu bağlamda, gölge analizi binaların güneş ışınımı alımını değerlendirme amacıyla yapılan analizlerle yakından ilişkilidir ve genellikle birlikte değerlendirilirler (Biljecki vd., 2015).

Literatüre bakıldığında yapılan pek çok çalışmada gölge analizi ya da içinde gölge analizini içeren güneş enerjisi potansiyeli analizlerinin 3B değil de 2.5B yüzey modelleri kullanılarak yapıldıkları ve bu çalışmalarda da 3B temsil gerektiren dikey yüzeylerin göz ardı edildiği görülmektedir. Suprojo vd. (2022), binalar ve bitki örtüsünden kaynaklanan gölge etkilerini analiz etmişlerdir. Çalışmalarında, sayısal yüzey modeli kullanarak bina çatılarının güneş enerjisi potansiyelini analiz etmişlerdir. Potansiyel güneş enerjisi üretimini kapsamlı bir şekilde değerlendirebilmek için gölge analiziyle birlikte rüzgâr yönü ve eğim gibi çeşitli faktörlerin dikkate alınmasının önemini vurgulamıştır. Cenky vd. (2024) yaptıkları çalışmada Slovakya'nın Bratislava şehrindeki bina çatılarının güneş enerjisi potansiyelini analiz etmişlerdir. Güneş enerjisini hesaplamak için gölge analizi yapmış ve bunu yapmak için de açık kaynak kodlu CBS yazılımı olan GRASS'ın r.sun modülünden yararlanmışlardır. Adjiski vd. (2023) yaptıkları çalışma ile LiDAR verisinden üretilen sayısal yüzey modeli ve sayısal arazi modeli kullanılarak güneş potansiyeli analizi yapılmıştır. Binaların cepheleri olan dikey yüzeyler göz ardı edilmiştir.

Clementi vd. (2024) tarafından yapılan çalışmada LiDAR verisinden üretilen sayısal yükseklik modeli kullanılarak güneş potansiyeli analizi yapılmış, dikey yüzeyler göz ardı edilmiştir. Soha vd. (2024) tarafından yapılan çalışmada LiDAR verisi kullanılarak kent ölçeğinde binaların çatıları için güneş potansiyeli analizi yapılmıştır. Bina cepheleri dikkate alınmamıştır. Massano vd. (2023) tarafından yapılan çalışmada CBS tabanlı güneş paneli elektrik üretim potansiyelinin değerlendirilmesini sağlayan prosedürler geliştirmişlerdir. Bu çalışmada sayısal yüzey modeli kullanılmış ve dikey yüzeyler göz ardı edilerek sadece çatılar dikkate alınmıştır. Baghani (2023) tarafından yapılan çalışmada İHA kullanılarak kırsal alanlardaki çatıların güneş enerjisi potansiyelinin analizi yapılmıştır. Dış cepheler göz ardı edilmiştir. Bhattacharya vd. (2019) tarafından yapılan çalışmada bina ayak izleri ve LiDAR nokta bulutu verisi kullanılarak binaların etraflarında oluşturduğu gölge etkisi analiz edilmiş, binaların kendi dikey yüzeyleri üzerinde oluşturdukları gölge etkisi göz ardı edilmiştir. Zaten bu eksiklik makalenin başlığındaki 2.5B ifadesinden de anlaşılmaktadır. Benzer şekilde Bhattacharya vd. (2021) LiDAR verisinden elde edilen sayısal yüzey modeli kullanarak 2.5B gölge haritası üretmiştir. Dikey yüzeyler göz ardı edilmiştir.

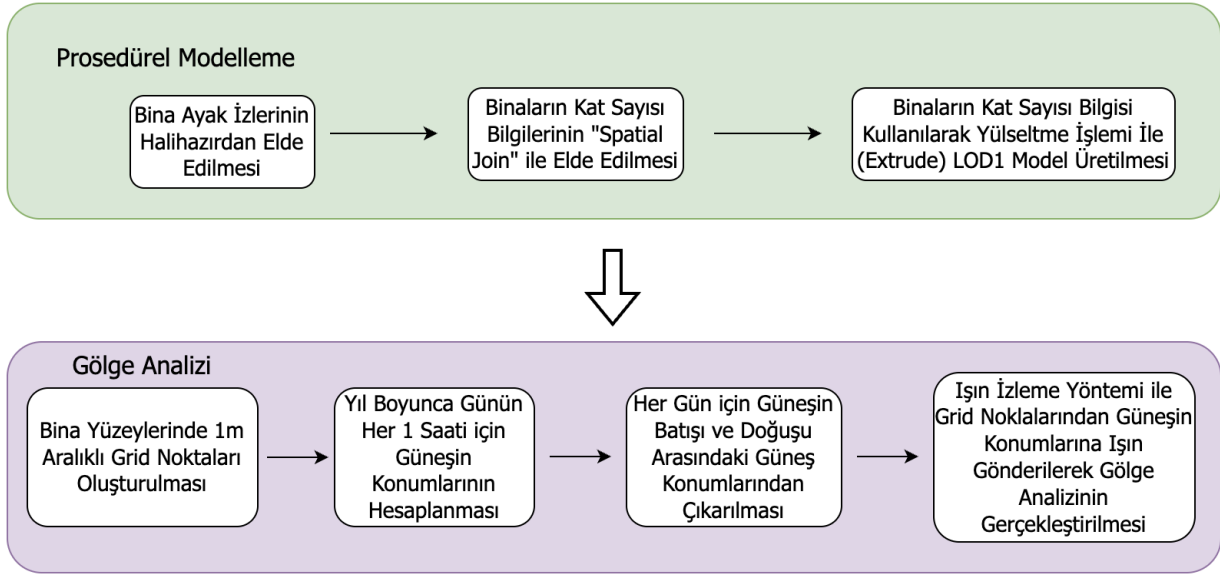
Rai ve Trivedi (2024), yaptıkları çalışmada Shadowmap isimli web tabanlı yazılım bileşenini kullanarak 3B olarak güneş potansiyeli analizi yapmışlardır. Bu yazılım bileşeni, konumsal veri olarak OpenStreetMap (OSM) verisini kullanmaktadır. OSM verisindeki binalar, yükseklik bilgisi özneteliği kullanılarak yükseltilmekte (extrude) ve 3B binalar oluşturulmaktadır (Şekil 1a). Yükseklik bilgisi bulunmayan binaların ise tümü, sabit bir değer ile aynı yüksekliğe yükseltilmektedir (Şekil 1b). Bu da yükseklik bilgisi olmayan binaların yanlış modellenmesine ve gölge etkisinin de yanlış hesaplanmasına neden olmaktadır. Yükseklik bilgisi olmayan binaların yükseklik değeri başka kaynaklardan elde edilerek ya da yapay zeka modelleri ile tahmin edilerek veri, modelleme öncesi zenginleştirilmelidir. Gölge analizinin 3B geometri kullanılarak gerçekleştirildiği bir diğer çalışma Xu vd. (2024) tarafından yapılan oldukça yeni bir çalışmadır. Bu çalışmada bina yüzeyleri üzerinde bir grid oluşturularak bu grid noktaları için gölge analizi ışın izleme algoritması ile aynen bu makaledeki gibi yapılmıştır. Ancak arada küçük bir fark vardır o da grid noktaları oluşturulurken bu çalışmada yüzeyler üzerinde 1m aralıklı düzenli dağılmış noktalardan oluşan bir grid oluşturulurken bahsi geçen çalışmada üçgen yüzeylerin orta noktaları kullanılarak düzensiz dağılmış bir grid oluşturulmaktadır. Bu çalışmadaki düzenli dağılmış noktalar bina yüzeyini daha doğru temsil etmekte ve analiz doğruluğuna pozitif yönde etki etmektedir. Aynı şekilde Alam vd. (2012) çalışmasında da grid düzensiz oluşturulmaktadır. 3B gölge analizi konusunda Türkiye’de yapılmış çalışmalar ise Konakoğlu ve Usta (2019), Usta ve Cömert (2015) ile Erbil ve Altay (2022)’dir. Konakoğlu ve Usta (2019) yaptıkları çalışmada bina yüzeyleri değil bina yüzeylerinin üzerinde gölge etkisi oluşturduğu peyzaj alanları analiz edilmiştir. Bahsi geçen çalışmada ShadowAnalysis isimli bir yazılım bileşeni kullanılmıştır. Bu bileşen, gölge analizi için zaman aralıklarını kullanıcıdan istemekte ve her bir saat için ışın izleme ile gölgeyi belirlemektedir. Yazılımın en büyük eksiği, kullanıcının girdiği zaman aralığını kontrol etmemesidir. Yıl boyunca güneşin doğuşu ve batışı her gün değişmektedir. Kullanıcının güneşin doğuş ve batışı arasındaki saatler dışında bir zaman aralığı girmesi halinde yazılım o zaman aralığını da analiz içine katmaktadır. Bu durum hem fazladan ışın yüzey kesişim testine neden olarak performansı kötü etkilemekte, hem de gün ışığının olmadığı karanlık saatlerin de gölge olarak değerlendirilmesine neden olmaktadır. Mevcut çalışmada bahsi geçen çalışmadan farklı olarak yılın her bir günü için sadece güneşin doğuş ve batışı arasında kalan saatler dikkate alınarak analiz gerçekleştirilmiştir. Usta ve Cömert (2015) tarafından yapılan çalışmada da aynı yazılım bileşeni kullanılmıştır. Aynı şekilde Erbil ve Altay (2022) aynı yazılım bileşenini kullanmışlardır ve yaptıkları çalışma, aynı sınırlamalara sahiptir.



Şekil 1. Shadowmap isimli 3B CBS aracı (Rai & Trivedi, 2024)


Panel kurulumları için uygun yer seçimi analizlerinde de gölge etkisi dikkate alınmıştır. Albraheem ve Alabdulkarim (2021), Riyad'da PV panellerin kurulumu için en uygun yerleri belirlemek amacıyla CBS tabanlı çok kriterli karar verme tekniklerini kullanmıştır. Bu çalışma, mekânsal analizlerin PV (fotovoltaik) kurulumları için saha seçimini nasıl yönlendirebileceğini göstermektedir.

İnteraktif modelleme, tek tek nesnelere düzenlemeyi gerektirdiğinden büyük ölçekli projelerde zaman alıcı ve hataya açık olabilir. Prosedürel modelleme, geniş alanlara yayılan çok fazla sayıda benzer özelliklere sahip objeleri, tekrarlayan yapıları daha interaktif modellemeye göre çok daha hızlı üretir. Bu bahsi geçen avantajlarından ötürü bu çalışmada prosedürel modelleme kullanılmıştır.



Şekil 3. Çalışmaya ait iş akışı

Öncelikle çalışma alanına ait halihazır verisi kullanılarak, her bir bina için, halihazırda yazı olarak yer alan kat sayısı verisi, "spatial join" analizi kullanılarak binaların öznitelik tablosuna otomatik olarak yazdırılmıştır. Daha sonra bu kat sayısı öznitelik verisi kullanılarak bina yükseklikleri kat sayısı * 3 olacak şekilde elde edilmiştir. Her bir bina için hesaplanan bu yükseklik verisi kullanılarak binalar yükseltilmiş ve LOD1 ayrıntı düzeyindeki 3B modeller elde edilmiştir (Şekil 4). Modelleme işlemi için Python programlama dilinde bir program yazılmış olup, oluşturulan 3B model CityJSON (Ledoux, 2019) formatında program tarafından kaydedilmiştir. Bunun için açık kaynak kodlu Python kütüphanesi "cjo" kullanılmıştır.




Şekil 4. Seyitler yerleşkesinin 3B modeli

3.3 3B Gölge Analizi

Gölge analizi için Işın izleme algoritmasından yararlanılmıştır. Işın izleme, bilgisayar grafiklerinden simülasyona pek çok alanda kullanılan bir algoritmadır. Işın izleme algoritmasının seçilmesinin nedeni raster tabanlı yöntemler gibi 2.5B ile sınırlı olmaması, Gökyüzü görünürlük faktörü (sky view factor) yöntemi kadar yüksek performans gerektirmemesidir (Xu vd., 2024). Işın izleme, noktalar arasındaki görünürlüğü hesaplamak için kullanılan bir tekniktir. Bu algorithmada ışın, başlangıç noktası ve doğrultusu olan vektörel bir büyüklüktür. Görülebilirlik analizlerinde, ışın bir noktadan diğerine doğru gönderilir ve yol boyunca ışın yüzey kesişim testleri yapılarak iki nokta arasında başka bir objenin varlığı araştırılır. Eğer ışın yüzey kesişim testi sonucu iki nokta arasında obje algılanırsa bu iki nokta birbirini görmemektedir sonucuna varılır. Gölge analizi de aslında bir görülebilirlik problemidir. Güneşin anlık konumundan bakıldığında görülebilen yerler güneş almakta görülemeyen yerler ise gölgede kalmaktadır. Bu nedenle bu problem ışın izleme ile çözülebilmektedir. Güneşin konumu, dünyanın güneş ve kendi etrafında dönmesi sebebiyle sürekli değişmektedir. Önceki aşamada elde edilen CityJSON dosyası kullanılarak gölge analizi için bina yüzeyleri üzerinde 1m aralıklı grid noktaları oluşturulmuştur.


Güneşin konumu, 1 saatlik zaman aralıklarında her saat için grid noktalarının enlem ve boylam bilgisi kullanılarak tüm yıl için hesaplanmıştır. Daha sonra Işın İzleme (Ray-Tracing) algoritması kullanılarak güneşin saatlik konumlarından bina yüzeyi üzerindeki gridlerin orta noktasına ışınlar gönderilmiş ve ışın-yüzey kesişim testi kullanılarak ışınların bina yüzeyleri ile kesişip kesişmediğine bakılmıştır. Eğer kesişim varsa o saat için yüzey gölge etkisindedir. Eğer kesişim yoksa o saat için yüzey doğrudan güneş ışığı almaktadır. Bu şekilde binanın çatı ve dış yüzeyleri için yıllık 3B gölge analizi gerçekleştirilmiştir (Şekil 5). Bu işlem için Python programlama dilinde program yazılmıştır.




Şekil 5. 3B Gölge analizi sonucu bina yüzeyleri ve toplam yıl boyunca aldıkları güneş ışığı süresi

4. Bulgular ve Tartışma


Yapılan 3B gölge analizi sonucunda, Seyitler ve Merkez Yerleşkelerindeki binaların sadece çatılarının değil dış cephelerinin de yeterli miktarda güneş ışığı aldığı görülmüştür. Seyitler Yerleşkesindeki binalar büyük çoğunluğu arasında yeterli mesafe olduğu ve bu nedenle birbirleri üzerinde çok fazla gölge etkisi oluşturmadıkları belirlenmiştir. Gölge etkisinin Merkez Yerleşkesindeki birbirlerine yakın mesafedeki yüksek binalar arasında olduğu görülmektedir (Şekil 6) ve (Şekil 7). Ayrıca aralarındaki yükseklik farkları fazla olan binaların komşu alçak binaların çatı yüzeylerinde dahi gölge etkisi oluşturduğu görülmüştür (Şekil 8). Oysa bu durumun Shadowmap adlı tüm binaların eşit yükseklikte modellendiği yazılım ile tespit edilmesinin mümkün olmadığı net bir şekilde ortaya konmuştur. Buradan hareketle, imar planları hazırlanırken 3B gölge analizlerinin kullanılması gerektiği ve özellikle bina yükseklikleri ve çekme mesafeleri gibi gölge etkisini belirleyici nitelikteki parametrelerin belirlenmesinde analiz sonuçlarının da dikkate alınması gerektiği görülmüştür.



Şekil 6. Merkez yerleşke gölge analizi sonucu




Şekil 7. Merkez yerleşkedeki birbirine yakın binalar ve aralarında artan gölge etkisi



Şekil 8. Merkez yerleşkede iki yüksek binanın aralarındaki alçak binanın çatısında oluşturdukları gölge etkisi

Artvin ilinde güneşin doğuş ve batış süreci arasında izlediği yol Güney yönelimli olduğundan Güneydeki bina cephelerinin Kuzey cephelere göre çok daha fazla güneş ışığı aldığı görülmektedir (Şekil 9). Buna göre en çok çatılar, daha sonra Doğu ve Batı yönlü cepheler ve son olarak da Kuzey yönlü cepheler güneş ışığına maruz kalmaktadır. Çatılar daha yüksek güneş ışığı alsa da dış cephelerin de anlamlı miktarda güneş ışığı aldığı, gerektiğinde dış cephelere de güneş paneli kurulumu yapılabileceği ve dolayısıyla gölge analizlerinde çatılar dışında dış cephelerin de dikkate alınması gerektiği görülmüştür.



Şekil 9. Bina cephelerinin Kuzey yönünden görünümü

5. Sonuç

Bu çalışmada 3B gölge analizinin bir kent analitiği aracı olarak nasıl kullanılabilirliği gösterilmiştir. Bu amaçla öncelikle çalışma alanı olan Artvin Çoruh Üniversitesi Seyitler Yerleşkesinin 3B modeli üretilmiştir. Üretilen bu 3B model kullanılarak gölge analizi sadece çatıları değil dış cepheleri de dikkate alacak şekilde 3B olarak gerçekleştirilmiştir. Yapılan analiz sonucunda dış cephelerinde oldukça güneş ışığı aldığı ve güneş paneli kurulumu için potansiyel taşıdığı görülmüştür. Bu çalışma göstermiştir ki gölge analizi bir kent analitiği aracı olarak planlama çalışmalarında dikkate alınmalı sadece çatıların değil dış cephelerin de analizi yapılmalıdır.

Teşekkür

Bu çalışma, Artvin Çoruh Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü (AÇÜBAP) tarafından desteklenmiştir (Proje No: 2023.F40.02.01).

Kaynaklar

- Albraheem, L., & Alabdulkarim, L. (2021). Geospatial analysis of solar energy in Riyadh using a GIS-AHP-based technique. *ISPRS International Journal of Geo-Information*, 10(5), Article 291. <https://doi.org/10.3390/ijgi10050291>
- Adjiski, V., Kaplan, G., & Mijalkovski, S. (2023). Assessment of the solar energy potential of rooftops using LiDAR datasets and GIS-based approach. *International Journal of Engineering and Geosciences*, 8(2), 188–199.
- Alam, N., Coors, V., Zlatanova, S., & Oosterom, P. J. M. (2012). Shadow effect on photovoltaic potentiality analysis using 3D city models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39, 209–214.
- Baghani, A. (2023). Assessment of rooftop solar power potential in rural areas using UAV photogrammetry and GIS. *Renewable Energy Research and Applications*, 4(2), 251–258.
- Bhattacharya, S., Braun, C., & Leopold, U. (2019, May 3–5). A novel 2.5D shadow calculation algorithm for urban environment [Conference presentation]. 5th International Conference on Geographical Information Systems Theory, Applications and Management (GISTAM 2019), Heraklion, Crete, Greece.
- Bhattacharya, S., Braun, C., & Leopold, U. (2021). An efficient 2.5D shadow detection algorithm for urban planning and design using a tensor-based approach. *ISPRS International Journal of Geo-Information*, 10(9), Article 583. <https://doi.org/10.3390/ijgi10090583>
- Biljecki, F., Stoter, J., Ledoux, H., Zlatanova, S., & Çöltekin, A. (2015). Applications of 3D city models: state of the art review. *ISPRS International Journal of Geo-Information*, 4(4), 2842–2889.
- Cenky, M., Bendik, J., & Lazarenko, I. (2024, October 16–18). Rooftop photovoltaic potential estimation using QGIS and simple building shadow analysis [Conference presentation]. 2024 International Conference on Smart Systems and Technologies (SST), Osijek, Croatia.
- Clementi, M., Dessi, V., Podestà, G. M., Chien, S. C., Wei, B. A. T., & Lucchi, E. (2024). GIS-based digital twin model for solar radiation mapping to support sustainable urban agriculture design. *Sustainability*, 16(15), Article 6590. <https://doi.org/10.3390/su16156590>
- El-Hosaini, H. (2015). Locating and positioning solar panels in a 3D city model: A case study of Newcastle, UK. *Journal for Geographic Information Science*, 3, 147-157. <https://doi.org/10.1553/giscience2015s147>
- Erbil, Z. C., & Altay, B. (2023). The relationship between shadow analysis and sustainability in university campuses: The example of Selcuk University Alaeddin Keykubat Campus. *Turkish Journal of Agriculture-Food Science and Technology*, 11(2), 343–347.
- Gui, B., Sam, L., & Bhardwaj, A. (2024). From roofs to renewables: Deep learning and geographic information systems insights into a comprehensive urban solar photovoltaic assessment for Stonehaven. *Energy* 360, 1, Article 100006. <https://doi.org/10.1016/j.energ.2024.100006>
- Konakoğlu, S. S. K., & Usta, Z. (2019, 23–25 Ekim). *Ekolojik sürdürülebilirlik kavramının 3B gölge analizi ile KTÜ Kanuni Kampüsü örneğinde irdelenmesi* [Bildiri sunumu]. TMMOB 6. Coğrafi Bilgi Sistemleri Kongresi, Ankara, Türkiye.
- Kuru, A. (2023). Solar power plant site selection modeling for sensitive ecosystems. *Clean Technologies and Environmental Policy*, 25(8), 2529–2544.
- Massano, M., Macii, E., Lanzini, A., Patti, E., & Bottaccioli, L. (2023). A GIS open-data co-simulation platform for photovoltaic integration in residential urban areas. *Engineering*, 26, 198–213.
- Ni, H., Wang, D., Zhao, W., Jiang, W., Mingze, E., Huang, C., & Yao, J. (2024). Enhancing rooftop solar energy potential evaluation in high-density cities: A deep learning and GIS-based approach. *Energy and Buildings*, 309, Article 113743. <https://doi.org/10.1016/j.enbuild.2023.113743>
- Ninsawat, S., & Hossain, M. D. (2016). Identifying potential areas and financial prospects of rooftop solar photovoltaics (PV). *Sustainability*, 8(10), Article 1068. <https://doi.org/10.3390/su8101068>
- Omar, K. S., Moreira, G., Hodczak, D., Hosseini, M., Colaninno, N., Lage, M., & Miranda, F. (2024). Deep Umbra: A generative approach for sunlight access computation in urban spaces. *IEEE Transactions on Big Data*, 11(2), 388–401.
- Rai, B., & Trivedi, R. (2024, February 21–23). Analysis of effects on solar energy generation due to mountain shadow on Sikkim Manipal Institute of Technology, Sikkim using Shadowmap 3D GIS mapping tool [Conference presentation]. 4th International Conference on Innovative Practices in Technology and Management (ICIPTM), Noida, India.

- Soha, T., Sugár, V., & Hartmann, B. (2024). City-scale analysis of PV potential and visibility in heritage environments using GIS and LiDAR. *Energy and Buildings*, 311, Article 114124. <https://doi.org/10.1016/j.enbuild.2024.114124>
- Suprojo, B., Utami, W., Saraswati, L. A., Nabila, D. A., & Salim, M. N. (2022). Digital earth surface model for the estimation of solar panel electric power towards renewable energy. *Geoplanning: Journal of Geomatics and Planning*, 9(2), 103–120.
- Şenol, H. İ. (2022). Investigation of the shadow effect of urbanization on green areas with shadow impact analysis. *Mugla Journal of Science and Technology*, 8(1), 26–30.
- Şenyurdusev, G., & Doğru, A. Ö. (2021). Akıllı şehir uygulamaları için prosedürel 3B kent modeli oluşturulması ve fotorealistik 3B görselleştirme. *Türk Uzaktan Algılama ve CBS Dergisi*, 2(2), 67–75.
- Usta, Z., Akın, A. T., & Cömert, Ç. (2023). Deep learning-aided web-based procedural modeling of LOD2 city models. *Earth Science Informatics*, 16(3), 2559–2571.
- Usta, Z., & Cömert, Ç. (2015, September 18–20). *Deriving solar energy potential of buildings in a 3D city model* [Conference presentation]. First International Conference on Sea and Coastal Development in the frame of Sustainability, Trabzon, Turkey.
- Xu, L., León-Sánchez, C., Agugiaro, G., & Stoter, J. (2024). Shadowing calculation on urban areas from semantic 3D city models. In T. H. Kolbe, A. Donaubaue, & C. Beil (Eds.), *Recent Advances in 3D Geoinformation Science* (pp. 31–47). Springer.
- Vo, A. V., & Laefer, D. F. (2019). A big data approach for comprehensive urban shadow analysis from airborne laser scanning point clouds. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 131–137.
- Zhou, K. L., & Gorte, B. G. H. (2017). Shadow detection from VHR aerial images in urban areas by using 3D city models and a decision fusion approach. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 579–586.

Analitik Hiyerarşi Yöntemi ile En Uygun Okul Yer Seçim Analizi: Elazığ Merkez Örneği

School Site Selection Analysis Using the Analytic Hierarchy Process: The Case of Elazığ City Center

Utkan Mustafa Durdağ^{1*}, Mehmet Sait Şen², Ziya Usta¹

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

²Atatürk Mesleki ve Teknik Anadolu Lisesi, 62000, Tunceli/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Utkan Mustafa Durdağ
umduddag@artvin.edu.tr

doi: 10.48123/rsgis.1603131

Yayın süreci

Geliş tarihi: 17.12.2024
Kabul tarihi: 19.03.2025
Basım tarihi: 26.03.2025

Özet

Ülkemizde meydana gelen depremler Elazığ ilini de ciddi şekilde etkileyerek birçok eğitim kurumunun ağır hasar görmesine ve yıkılmasına yol açmıştır. Bu durum, yeni yapılacak okul alanlarının daha uygun ve güvenli yerlerde inşa edilmesi gerekliliğini bir kez daha gündeme getirmiştir. Bu çalışmada, çalışma alanı için 15 uygun kriter belirlenerek Elazığ İli Merkez İlçesi için en uygun okul alanlarının tespit edilmesi hedeflenmiştir. Çalışmada, ÇKKV (Çok Kriterli Karar Verme) yöntemlerinden Analitik Hiyerarşi Yöntemi (AHY) kullanılarak belirlenen kriterlerin ağırlıkları hesaplanmıştır. Ağırlık değerlerine göre, nüfus(%19), mevcut okullara yakınlık(%16) ve dere yataklarına uzaklık(%13) kriterleri toplam ağırlığın yaklaşık yarısını oluşturarak en etkili faktörler olurken, yüksek basınçlı doğalgaz hattına uzaklık(%1) ve yönlenme(%1) en az etkili kriterler arasında yer almıştır. CBS yardımıyla oluşturulan kriter haritaları kullanılarak ağırlıklı çakıştırma analizi gerçekleştirilmiş ve uygunluk haritaları elde edilmiştir. Bu haritalar aracılığıyla en uygun okul alanları tespit edilmiş, ayrıca mevcut okul alanlarının uygunluk durumları değerlendirilmiştir. Sonuçlara göre, çalışma alanının %95,93'ü uygun olmayan alanlar, %2,02'si az uygun alanlar, %1,99'u uygun alanlar ve %0,05'i çok uygun alanlar olarak sınıflandırılmıştır. Çalışma sonucunda elde edilen veriler, gelecekte okul planlaması ve yer seçiminde yol gösterici olabilecek niteliktedir.

Anahtar kelimeler: Okul yer seçimi, CBS, Çok kriterli karar verme, AHY

Abstract

The earthquakes that occurred in our country seriously affected Elazığ province and caused many educational institutions to be severely damaged and destroyed. This situation has once again brought to the agenda the necessity of building new school areas in more suitable and safe places. In this study, it is aimed to determine the most suitable school areas for the Central District of Elazığ Province by determining 15 appropriate criteria for the study area. In the study, the weights of the criteria were calculated using the Analytic Hierarchy Process (AHP), one of the MCDM (Multi-Criteria Decision Making) methods. According to the weight values, population (19%), proximity to existing schools (16%) and distance to stream beds (13%) were the most influential factors, accounting for about half of the total weight, while distance to high pressure natural gas line (1%) and orientation (1%) were among the least influential criteria. Weighted overlapping analysis was performed using the criteria maps created with the help of GIS and suitability maps were obtained. Through these maps, the most suitable school areas were identified and the suitability status of the existing school areas was evaluated. According to the results, 95.93% of the study area was classified as unsuitable areas, 2.02% as less suitable areas, 1.99% as suitable areas and 0.05% as very suitable areas. The data obtained as a result of the study can guide school planning and site selection in the future.

Keywords: School site selection, GIS, Multi-criteria decision making, AHP

1. Giriş

Eğitim sürecinin daha verimli işlemesi ve ülkemizin kaynaklarının etkin bir şekilde kullanılması için eğitim alanlarının uygun konumda ve planlı bir şekilde inşa edilmesi gerekmektedir. Ülkemizde okul alanlarının uygun konumda olması ve sistematik plan dahilinde yapılması bir problem olarak karşımıza çıkmaktadır. Ülkemizde 6-18 yaş aralığındaki öğrencilerin eğitim süreçleri göz önüne alındığında (okul öncesi, ilk ve orta öğretim) zamanlarının çoğunu okulda geçirdiği görülmektedir. Bu sebeple öğrencilere sağlıklı ve güvenli bir okul ortamı sağlamak gerekmektedir (Bukhari vd., 2012). Uygun okul alanlarının belirlenmesi sürecinde, planlama aşamasında titiz bir değerlendirme yapılması gerekmektedir. Uygun okul alanlarının yer seçimi, artan nüfus, yeni yerleşim alanlarının oluşumu, depremler gibi doğal afetler sonucunda hasar gören okul binalarının yeniden inşası ve mevcut okulların yetersizliği gibi nedenlerle hem ülkemizde hem de dünyada önemli bir konu olarak karşımıza çıkmaktadır. Bu doğrultuda, geçmişten günümüze çok sayıda çalışma yapılmış ve genellikle Çok Kriterli Karar Verme (ÇKKV) yöntemleri tercih edilmiştir. Çalışmalarda, kullanılan kriterlerin araştırılmasıyla birlikte, ÇKKV yöntemlerinden Analitik Hiyerarşi Yöntemi (AHY) ve İdeal Çözüme Benzerliğe Göre Sıralama Tekniği (TOPSIS) gibi yaklaşımların performansları da sıklıkla ele alınmıştır. AHY, Saaty (1977) tarafından geliştirilen, matematik ve psikoloji temelli bir teknik olup karmaşık kararları organize etmek ve analiz etmek için yapılandırılmış bir yöntemdir. Bu yaklaşım, karar vericiler bir problemi bileşenlerine ayırma, her bir bileşenin göreceli önemini değerlendirme ve bu değerlendirmeleri birleştirerek tercih edilen bir çözümü belirleme imkânı tanır. AHY; tarım arazileri üzerindeki baraj etkilerinin değerlendirilmesi (Akıncı vd., 2017), stratejik planlama (Akıncı vd., 2013), arazi kullanım uygunluk analizleri ve heyelan duyarlılığı değerlendirmesi (Akıncı vd., 2015; Polat vd., 2017) gibi çeşitli alanlarda, özellikle çok kriterli karar verme süreçlerinde Coğrafi Bilgi Sistemleri (CBS) ile birlikte etkin bir şekilde kullanılmaktadır.

Çalışma alanında, 24 Ocak 2020 tarihinde Elazığ'ın Sivrice ilçesinde meydana gelen 6.8 büyüklüğündeki ve 6 Şubat 2023 tarihinde Kahramanmaraş'ın Pazarcık ve Elbistan ilçelerinde sırasıyla 7.7 ve 7.6 büyüklüğündeki depremler, bölgeyi ciddi şekilde etkilemiştir. Bu depremler sonucunda birçok eğitim kurumu ağır hasar görmüş, yıkılmış ve yerlerine yeni okul alanlarının inşası tamamlanmış ya da halen devam etmektedir. Bu çalışmada, uygun okul alanlarının belirlenmesinde dikkate alınması gereken kriterlerin tanımlanması ve bu kriterlere dayalı analizlerin CBS ve ÇKKV yöntemleri ile gerçekleştirilmesi amaçlanmaktadır. Ayrıca mevcut okul alanlarının ve yapım aşamasında olan yeni okul projelerinin uygunluk haritası üzerinde değerlendirilmesi hedeflenmiştir. Çalışma kapsamında, Dünyada ve Türkiye'de kullanılan kriterler göz önüne alınarak çalışma alanı için uygun kriterlerin belirlenmesi ve bu kriterlerin ağırlıklarının hesaplanması planlanmaktadır.

2. Benzer Çalışmalar

En uygun okul yer seçimi konusunda literatürde birçok çalışma yapılmıştır. Qubaisi vd. (2016), eğitim yönetiminde AHY'nin faydasını göstererek, eşleşmeli karşılaştırmalar yoluyla en iyi alternatiflerin seçimini nasıl kolaylaştırdığını ortaya koymuştur. Bu yöntem, okul yeri seçiminde olduğu gibi hem nicel hem de nitel faktörlerin dikkate alınması gereken durumlarda özellikle yararlıdır. Uslu vd.(2017), Ankara'nın Çankaya ilçesinde ilköğretim okulu yer seçimi için AHY ve TOPSIS yöntemlerini kullanmış ve altyapı, erişilebilirlik, potansiyel büyüme, nüfus yoğunluğu, güvenlik, çevre kirliliği ve çevredeki okul sayısı gibi yedi kriter belirlemiştir. Bu kriterler arasında en önemlisinin nüfus olduğu sonucuna ulaşmışlardır. Benzer şekilde, Keleş (2022), Kayseri'de yaptıkları çalışmada okul yer seçimi kriterlerinin uzman görüşleriyle belirlenmesi gerektiğini vurgulamış ve AHY ile bu kriterlerin ağırlıklarını analiz etmiştir. Başeğmez vd. (2017), okul alanlarının belirlenmesinde karşılaşılan sorunları ele almış ve imar planlarının hazırlanmasında dikkat edilmesi gereken kriterlere değinmiştir. Ayrıca, Türkiye'deki mevzuatın incelenmesi sonucunda CBS entegreli yeni bir düzenlemenin gerekliliğine dikkat çekmişlerdir. Başka bir çalışmada, Başeğmez (2019), Uşak ili Merkez ilçesindeki okul alanlarının belirlenmesinde karar verici çokluğu nedeniyle karşılaşılan zorluklara değinmiş ve bu sorunların çözümünde CBS ile ÇKKV yöntemlerinin önemini vurgulamışlardır. Zor (2020), Denizli ilindeki çalışmasında, ilköğretim ve ortaöğretim okulları için yer seçiminde etkili olan faktörleri belirlemek amacıyla yerel aktörlerle yüz yüze görüşmeler gerçekleştirmiştir. Çalışmada, yanlış yer seçiminin güvenlik, trafik ve ekonomik sorunlar gibi pek çok olumsuzluğa yol açtığı sonucuna varılmıştır. Ayrıca, eğitim alanlarının planlanmasında Milli Eğitim Bakanlığı'nın belirleyici bir rol üstlenmesi gerektiği savunulmuştur.

AHY'nin bulanık mantıkla entegrasyonu, eğitim bağlamındaki uygulanabilirliğini daha da artırmıştır. Shi (2012), öğrenci not istatistiklerini değerlendirmek için bir bulanık AHY yaklaşımı önermiş ve bu yöntemin okul yerlerinin değerlendirilmesinde de kullanılabileceğini göstermiştir. Bulanık mantığın AHY ile birleştirilmesi, toplumsal duyarlılık veya çevresel etkiler gibi kolayca nicel hale getirilemeyen kriterlerin daha ayrıntılı bir şekilde değerlendirilmesine olanak tanımaktadır. Bukhari vd. (2012) Malezya'daki çalışmasında, AHY kullanılarak güvenli okul yer seçimi için sanayi bölgelerine uzaklık, ticari alanlara yakınlık ve hava kirliliği gibi kriterlerin dikkate alındığı görülmüştür.

Dadfar (2014), ABD'nin Calabahas şehrindeki lisenin uygunluk analizinde mevcut liseye uzaklık, 18 yaş altı nüfus yoğunluğu ve arazi kullanımı gibi altı kriteri TOPSIS yöntemiyle değerlendirmiştir. Benzer şekilde, Abera (2019), Etiyopya'nın Addis Ababa şehrinde CBS entegreli AHY kullanarak ekonomik, erişilebilirlik ve çevresel güvenlik başlıkları altında toplanan kriterlerle uygun okul alanlarını analiz etmiştir. Ahmed Ali (2018), Irak'ın Babil ili El-Mahaweel ilçesinde yürüttüğü çalışmada, eğitim, ana yollar, 14 yaş altı nüfus yoğunluğu ve mevcut okullar gibi kriterleri kullanarak uygunluk haritasını oluşturmuş ve bu alanları iyi, orta ve kötü olarak sınıflandırmıştır. Samad vd. (2012), Malezya'da okul alanlarının belirlenmesinde AHY'yi uygulamış ve 19 yaş altı nüfus yoğunluğu, nehir ağı ve yol ağı gibi kriterleri değerlendirmiştir. Talam ve Ngigi (2015) ise Kenya'da 12 farklı kriterle okul alanı belirleme sürecini CBS ve ÇKKV yöntemlerini entegre ederek incelemiştir.

AHY okul alanlarının belirlenmesi dışında da pek çok çalışmada kullanılmıştır. Eğitim bağlamında AHY çerçevesi, okul öncesi seçim sistemleri (Mamat vd., 2017) ve eğitim ekipmanlarının verimliliğinin değerlendirilmesi (Wang & Peng, 2011) gibi çeşitli uygulamalara uyarlanmıştır. Mamat vd. (2017) okul öncesi seçiminde AHY'nin kullanılabilirliğini vurgulayarak, yöntemin ebeveyn tercihlerini ve kurumsal gereksinimleri yansıtan çeşitli kriterleri içerebilme kapasitesine dikkat çekmiştir. Bu uyarlanabilirlik, erişilebilirlik, güvenlik ve toplumsal ihtiyaçlar gibi faktörlerin dikkate alınmasının gerektiği okul yeri seçiminde kritik bir öneme sahiptir. AHY'nin yenilikçi eğitim bağlamındaki uygulamaları da araştırılmıştır. Mondal ve Mukherjee (2016), yöntemin eğitim kalitesinin analizindeki rolünü vurgulayarak, AHY'nin bu karmaşık sorunlarla başa çıkmadaki etkinliğini göstermiştir. Okul yeri seçimi gibi, çoklu kriterlere dayalı alternatiflerin sıralanmasının gerektiği durumlarda bu yaklaşımın önemi daha da artmaktadır. Coğrafi Bilgi Sistemleri (CBS) de AHY ile birleştirilerek yer seçimi süreçlerindeki karar verme yetkinliği artırılmıştır. Örneğin, Abdulhasan vd. (2019), CBS ve AHY'nin katı atık bertaraf alanı seçiminde etkin bir şekilde nasıl kullanıldığını göstermiş ve bu yöntemin okul yeri analizine uyarlanabilir olduğunu vurgulamıştır. CBS ile mekânsal verilerin kullanılması, nüfus yoğunluğu, mevcut altyapı ve çevresel etki gibi faktörlerin değerlendirilmesine olanak sağlamaktadır. AHY sürecinde paydaş katılımının önemi göz ardı edilemez. Smith ve Bayazit (2020), öğretim üyelerinin seçimi üzerine yaptıkları çalışmada, paydaşların algı ve yargılarının karar verme sürecindeki kritik rolünü vurgulamışlardır. Bu bulgular, okul yeri seçiminde topluluk değerleri ve eğitim hedefleriyle uyumlu bir seçim yapılmasını sağlamak için çeşitli bakış açılarını içermenin önemini ortaya koymaktadır.

AHY uygulamalarında teknolojinin rolü de giderek daha fazla tanınmaktadır. Wang vd. (2021), yeni iletişim teknolojilerinin eğitimdeki potansiyeline dikkat çekmiş ve bu teknolojilerin AHY çerçevelerine entegre edilmesi gerektiğini savunmuştur. Bu tür teknolojik ilerlemeler, veri toplama ve analiz süreçlerini kolaylaştırarak okul yeri seçeneklerinin daha kapsamlı bir şekilde değerlendirilmesine olanak tanıyabilir. Bununla birlikte, AHY'nin eğitim bağlamında uygulanmasında karşılaşılan zorluklar da önemlidir. Haji vd. (2017), kriter değerlendirmelerinin öznel doğasının karar verme sürecinde tutarsızlıklara yol açabileceğini belirtmişlerdir. Bu durumun önüne geçmek için açık yönergeler ve değerlendirme kriterleri belirlemek, AHY sürecinin güvenilirliğini artırabilir ve paydaşlar arasında daha büyük bir güven oluşturabilir. AHY'nin uygulama alanı geleneksel eğitim bağlamının ötesine uzanmaktadır. Mesleki rehberlik (Dawami vd., 2022) ve kırsal kalkınma (Baffoe, 2019) alanlarında yapılan çalışmalar, yöntemin karar verme zorluklarına çözüm sunmadaki esnekliğini göstermektedir. Bu çalışmalardan elde edilen yöntemlerin okul yeri seçiminde uyarlanması, hem eğitim hem de toplumsal ihtiyaçları göz önünde bulunduran daha etkili stratejilerin geliştirilmesine katkı sağlayabilir.

Sonuç olarak, literatürde yer seçiminde ÇKKV yöntemlerinden özellikle AHY'nin yaygın şekilde kullanıldığı ve bazı çalışmalarda AHY'nin diğer yöntemlerle birlikte uygulandığı görülmektedir. Kullanılan kriterler, çalışmanın yapıldığı bölgeye ve okul türüne göre farklılık gösterebilmektedir. Örneğin, nüfus kriteri bazı çalışmalarda genel nüfus, bazılarında ise 14 yaş altı nüfus ya da 18 yaş altı nüfus olarak ele alınmıştır. Bu çalışmaların incelenmesi, belirli bir bölge için uygun kriterlerin seçilmesine yönelik önemli bir temel oluşturmaktadır.

Tablo 1. Literatürde kullanılan yer seçimi kriterleri

Ana Yollara Yakınlık	Gürültü	Hava Kirliliği	Yüksek Elektrik Hatlarına Yakınlık	Taşkın Alanlarına Yakınlık
Akarsulara Uzaklık	Fabrikalara Yakınlık	Mevcut Okullara Yakınlık	Eğitim	Nüfus
Şehirlere Olan Uzaklık	19 Yaş Altı Nüfus Yoğunluğu	Ara Yola Yakınlık	Acil Durum Tesislerinden Uzaklık	Trafolara Uzaklık
Arazi Kullanımı	Toprak	Elektrik İletim Hatları	Jeoloji	14 Yaş Altı Nüfus
Ticari mesafe	Sanayi tesislerine yakınlık	İtfaiyelere yakınlık	Toplu Taşıma Güzergâhı	Yönlenme(Bakı)
Yüksek Basıncılı Doğalgaz Hatlarına Yakınlık	Demiryoluna Yakınlık	Havaalanına Yakınlık	Yeraltı Depolama Alanı	Altyapı
Yükseklik	Trafik Yoğunluğu	Akaryakıt İstasyonlarına Yakınlık	Erişebilirlik	Güvenlik
Meyhane, kıraathane bar, elektronik oyun merkezleri	Fay Hattına Uzaklık	Kimyasal Riskli Alanlara Uzaklık	Restoranlara Yakınlık	Baz İstasyonu
Yüz Ölçüm Büyüklüğü	Bataklık	Heyelan	Eğlence Yerleri	Rüzgâr Yönü
Manzara	Tehlikeli Atık Madde	Boru Hatları	İmar	Maliyet
Yer Altı Suyu Kirliliği	Erozyon	Doğal ve Kültürel Alanlara Yakınlık	Kültürel Yapı Durumu	Taşınmazın Mevcut Kullanımı

3. Metodoloji

Çalışmada verilerin işlenmesi ve analizinde ArcGIS 10.8 yazılımı kullanılmıştır. AHY ile kriterler ağırlıklandırılmış ve Microsoft Excel yazılımı kullanılmıştır. Yine veri toplama aşamasında kriterlere ait .NCZ formatındaki veriler NetCAD yazılımında düzenlenip CBS ortamına aktarılmıştır. Çalışmanın tüm analiz ve haritaları ArcGIS 10.8 yazılımı ile yapılmıştır.

Günümüzde karar vericilerin, elde ettikleri verileri analiz ederek alternatif modeller oluşturması ve bu analizlerden elde edilen sonuçları değerlendirmesi süreci, Çok Kriterli Karar Verme (ÇKKV) yöntemi olarak adlandırılmaktadır. ÇKKV yöntemi, günlük yaşamda alınan kararlardan büyük yatırım projelerine, taşınmaz alımlarından stratejik önceliklerin belirlenmesine kadar geniş bir yelpazede kullanılmaktadır. Aynı zamanda, işletme ve kurumların yer seçimi, devlet bütçesi dağılımı ve yatırım kararlarında da etkin bir araç olarak öne çıkmaktadır (Ünaldık, 2019). ÇKKV sürecinin temel aşamaları şu şekilde özetlenebilir: İlk olarak, karşılaşılan sorunlar detaylı bir şekilde analiz edilir ve problemin amacı ile gereksinimleri belirlenir (Akdemir, 2019). Daha sonra, literatürdeki çalışmalar incelenerek ve uzman görüşleri alınarak seçim kriterleri oluşturulur (Malczewski, 2006). Bu kriterler ışığında alternatif kararlar belirlenip değerlendirilir ve çözüm odaklı bir yaklaşım geliştirilir. Karar probleminin hiyerarşik yapısının oluşturulmasının ardından uygun yöntem belirlenir ve en uygun alternatif seçilerek karar süreci tamamlanır (Karabıçak vd., 2016).

ÇKKV yöntemleri arasında en sık kullanılanlar arasında Analitik Hiyerarşi Yöntemi (AHY), Analitik Ağ Süreci, İdeal Çözüme Benzerliğe Göre Sıralama Tekniği (TOPSIS), Uyum Yöntemi (ELECTRE), PROMETHEE ve VIKOR yöntemleri bulunmaktadır (Yücel, 2015). Bu çalışmada ise AHY tercih edilmiştir. Bunun nedeni, AHY'nin güçlü, kolay anlaşılabilir ve uygulanabilir bir yöntem olmasıdır. Ayrıca, bu yöntem birçok kriterin birbirine göre önem derecesini kıyaslamaya ve kriter ağırlıklarını belirlemeye olanak sağlamasıyla öne çıkmaktadır. AHY, karmaşık problemlerin çözümünü basitleştiren bir yöntemdir.

Çalışma alanı içerisinde 64 mahalle 135 köy bulunmaktadır. Çalışma alanının sınırları Özel Harita Bürosundan .NCZ formatında temin edilmiştir. ArcMap yazılımına aktarılarak Shapefile olarak düzenlenip koordinat sistemi tanımlanmıştır. Çalışmada World Geodetic System (WGS) 1984 Datumu ve Universal Transverse Mercator (UTM) projeksiyonu Zone 37N koordinat sistemi olarak kullanılmıştır (Şekil 2).

3.2 AHY ve Uygulama Adımları

3.2.1 Yer Seçim Kriterlerinin Belirlenmesi ve Verilerinin Temin Edilmesi

Çalışma alanında kullanılacak kriterler, güncel literatürdeki benzer çalışmalar, mevzuat bilgileri ve uzman görüşleri alınarak belirlenmiştir. Buna göre Tablo 2’de yer alan 15 adet kriter uygun yer seçimi analizi için dikkate alınmıştır.

Tablo 2. Yer seçimi kriterleri

Nüfus	Yüksek Orta Gerilim Hattına Uzaklık
Mevcut Okullara Olan Uzaklık	Arazi Kullanımı
Dere Yataklarına Uzaklık	Gürültü
Yerleşim Merkezlerine Yakınlık	Fay Hatlarına Olan Uzaklık
Eğim	Benzin İstasyonlarına Uzaklık
Toplu Taşıma Güzergâhına Yakınlık	Yüksek Basıncılı Doğalgaz Hattına Uzaklık
Ana Yola Uzaklık	Yönlenme(Bakı)
Meyhane, Bar, Kahvehaneye Uzaklık	

3.2.2 AHY İle Belirlenen Kriterlerin Ağırlıklandırılması ve Tutarlıklarının Belirlenmesi

Araştırma kapsamında çalışma alanına ilişkin nüfus dağılımı, mevcut okullara olan mesafe, dere yataklarından uzaklık, yerleşim merkezlerine (şehir ve köyler) olan yakınlık, topografik eğim, toplu taşıma hatlarına erişim, ana yollarla olan mesafe, sosyal etkileşim alanları (meyhane, kahvehane, bar, elektronik oyun merkezleri gibi) ile mesafe, yüksek ve orta gerilim hatlarının uzaklığı, arazi kullanım özellikleri, gürültü kaynakları (havaalanı, demiryolu gibi), fay hatlarına olan mesafe, akaryakıt istasyonlarının uzaklığı, yüksek basınçlı doğalgaz hatlarıyla olan mesafe ve yönlenme gibi kriterler, AHY kullanılarak ağırlıklandırılmıştır.

Uygulanan AHY’nin vereceği sonuçların kalite ve doğruluğunu, kriterleri karşılaştırma aşamasındaki yargıların tutarlığı önemli derecede etkilemektedir (Öztürk & Batuk, 2007). İkili karşılaştırma matrisinde kullanılan kriterler karmaşaya sebep vermemesi amacıyla aşağıda verildiği gibi kısaltmalar verilmiştir: Nüfus (K1), Mevcut Okullara Olan Uzaklık (K2), Dere Yataklarına Uzaklık (K3), Yerleşim Merkezlerine Yakınlık (K4), Eğim (K5), Toplu Taşıma Güzergâhına Yakınlık (K6), Ana Yollara Uzaklık (K7), Meyhane-Kahvehane-Bar-Elektronik Oyun Merkezlerine Uzaklık (K8), Yüksek Orta Gerilim Hattına Uzaklık (K9), Arazi Kullanımı (K10), Gürültü (K11), Fay Hatlarına Olan Uzaklık (K12), Akaryakıt İstasyonlarına Uzaklık (K13), Yüksek Basıncılı Doğalgaz Hattına Uzaklık (K14), Yönlenme (K15).

50 harita mühendisi ile yapılan anket sonucu elde edilen değerler Microsoft Office Excel programıyla ikili karşılaştırma matrisinde her kriter diğer tüm kriterlerle karşılaştırılarak birbirlerine olan üstünlükleri belirlenmiş ve 1’den 9’a kadar değer verilerek oluşturulmuştur (Tablo 3). Ayrıca elde edilen ağırlık değerleri ilgili literatür ile karşılaştırılmıştır (Kuru & Terzi, 2018; Başeğmez, 2019).

Tablo 3. İkili karşılaştırma matrisi

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	K15	AĞIRLIK
K1	1.000	2.000	2.000	3.000	3.000	4.000	5.000	5.000	6.000	6.000	7.000	8.000	8.000	9.000	9.000	0.1941
K2	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	7.000	7.000	8.000	8.000	9.000	0.1612
K3	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	7.000	7.000	8.000	8.000	0.1319
K4	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	7.000	7.000	8.000	0.1069
K5	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	7.000	7.000	0.0873
K6	0.250	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	7.000	0.0707
K7	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	6.000	0.0561
K8	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	5.000	0.0455
K9	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	5.000	0.0369
K10	0.167	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	5.000	0.0297
K11	0.143	0.143	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	3.000	0.0229
K12	0.125	0.143	0.143	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	3.000	0.0187
K13	0.125	0.125	0.143	0.143	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	2.000	0.0151
K14	0.111	0.125	0.125	0.143	0.143	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	2.000	0.0125
K15	0.111	0.111	0.125	0.125	0.143	0.143	0.167	0.200	0.200	0.200	0.333	0.333	0.500	0.500	1.000	0.0104

İncelenen literatür sonucunda, yapılan aşamaların tutarlı olması ve kabul edilebilmesi için CR (tutarlılık oranı) değerinin 0.10 dan küçük olması gerekmektedir (Saaty, 1980; Yılmaz, 2022; Kayalık & Polat, 2023a). Bu çalışmada da tutarlılık oranının 0.07 olarak hesaplanması, ağırlık değerlerinin karar verme işleminde kullanılmasının kabul edilebilir sonucunu göstermektedir. Bu oran Kriterlerin sınıf aralıkları ve ağırlık dereceleri Tablo 4’de verilmiştir.

Tablo 4. Kriterlerin sınıf aralıkları ve ağırlık dereceleri

KRİTERLER	ALT KRİTERLER	PUAN	AĞIRLIK
Nüfus (m ² /kişi)	0-0.50	1	% 19
	0.50-1.00	2	
	1.00-1.50	3	
	1.50-2.00	4	
	2.00	5	
Mevcut okullara olan uzaklık (m)	0-500	1	% 16
	500-1000	2	
	1000-1500	3	
	1500-2000	4	
	2000	5	
Dere yataklarına uzaklık (m)	0-100	0	% 13
	100-200	1	
	200-400	2	
	400-600	4	
	600	5	
Yerleşim (şehir) merkezlerine yakınlık (m)	0-500	5	% 8
	501-1000	4	
	1001-1500	3	
	1501-2000	2	
	2001	1	
Yerleşim (köy) merkezlerine yakınlık (m)	0-500	5	% 3
	501-1000	4	
	1001-1500	3	
	1501-2000	2	
	2001	1	

Tablo 4'ün devamı


KRİTERLER	ALT KRİTERLER	PUAN	AĞIRLIK
Eğim	0-5°	5	% 9
	5-10°	4	
	10-25°	3	
	25-40°	2	
	40°	1	
Toplu taşıma güzergâhına yakınlık (m)	0-100	5	% 7
	100-500	4	
	500-1000	3	
	1000-1500	2	
	1500	1	
Ana yola uzaklık (m)	0-100	0	% 6
	100-500	1	
	500-1000	3	
	1000-1500	4	
	1500	5	
Meyhane, bar, kahvehaneye uzaklık (m)	0-100	0	% 4
	100-200	1	
	200-300	3	
	300-400	4	
	400	5	
Yüksek orta gerilim hattına uzaklık (m)	200	0	% 3
	300	2	
	400	4	
	400	4	
	400	5	
Arazi kullanımı	Yapay Bölgeler	5	% 1
	Tarımsal Alan	0	
	Orman Alanları	1	
	Su Yüzeyleri	0	
Gürültü (havaalanı) (m)	0-500	0	% 1
	500-1000	1	
	1000-1500	3	
	1500-2000	4	
	2000	5	
Gürültü (demiryolu) (m)	0-50	0	% 1
	50-100	1	
	100-150	3	
	150-200	4	
	201	5	
Fay hatlarına olan uzaklık	0-2000	0	% 2
	2000-2500	1	
	2500-3000	2	
	3000-3500	4	
	3500	5	
Benzin istasyonlarına uzaklık	0-100	0	% 2
	100-150	3	
	150-200	4	
	200	5	
Yüksek basınçlı doğalgaz hattına uzaklık	0-100	0	% 1
	100-150	1	
	150-200	2	
	200-250	4	
	250	5	

Tablo 4'ün devamı

KRİTERLER	ALT KRİTERLER	PUAN	AĞIRLIK
Yönlendirme (bakı)	S	5	% 1
	SE-SW	4	
	E-W	3	
	NE-NW	2	
	N	1	

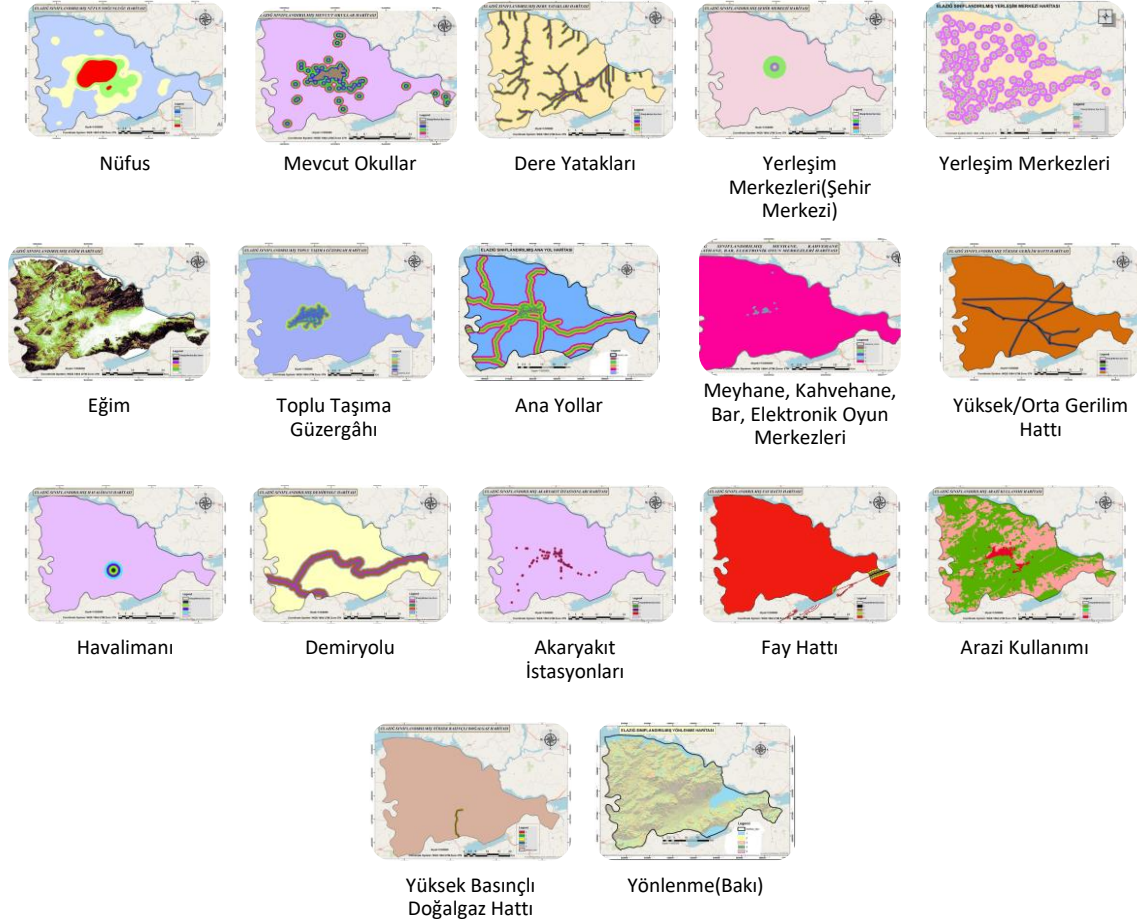
3.3 Çalışma Alanına Etki Eden Kriterler ve Analizler

Çalışma alanına etki eden kriterlere ait sözel, sayısal ve mekânsal bilgiler bir dizi düzenleme sonucunda ArcGIS programında kullanılabilir hale getirilmiştir. Tüm kriterler aynı koordinat sisteminde gösterilmek suretiyle uygun hale getirilerek analizler yapılmıştır (Şekil 3).



Şekil 3. Çalışma alanına göre düzenlenmiş kriter haritaları


Kriterlere ait analizler ArcGIS ortamında yapıldıktan sonra reclassify (yeniden sınıflandırılma) işlemi yapılarak ilgili kriterler sonuç haritası için uygun hale getirilmiştir (Şekil 4).



Şekil 4. Sınıflandırılmış kriterler

3.4 En Uygun Okul Alanı Yer Seçimi

Önceki adımlarda sınıflandırılmış raster veriler ve AHY ile bulunan ağırlık değerleri kullanılarak ağırlıklandırılmış toplam (weighted overlay) analizi ile okul uygunluk haritası elde edilmiştir (Şekil 5).



Şekil 5. AHY sonucu uygun ve uygun olmayan yerler

4. Bulgular ve Tartışma

AHY ile elde edilen ağırlık değerleri önem sırasına göre incelendiğinde, en etkili kriterler sırasıyla: Nüfus, mevcut okullara olan uzaklık, dere yataklarına olan uzaklık, yerleşim merkezlerine yakınlık, eğim, toplu taşıma güzergâhına yakınlık ve ana yola uzaklık olarak belirlenmiştir. Bunları; sosyal alanlara (meyhane, kahvehane, bar, elektronik oyun merkezleri) uzaklık, yüksek ve orta gerilim hattına uzaklık, arazi kullanımı, gürültü kaynaklarına uzaklık, fay hatlarına uzaklık, akaryakıt istasyonlarına uzaklık, yüksek basınçlı doğalgaz hatlarına uzaklık ve yönlenme kriterleri takip etmiştir.

Güler ve Yomralıoğlu (2020) ve Kayalık ve Polat (2023b) çalışmalarında sonuçların 4 farklı uygunluk ya da değer kategorilerine ayırdıkları görülmüştür. Buradan hareketle bu çalışmada AHY ile belirlenen okul alanları, literatürle uygun olacak şekilde, uygun değil, az uygun, uygun ve çok uygun olarak 4 gruba ayrılmıştır. En uygun okul alanları yer seçimi haritasında, çalışma alanının %95,93'ü (216.178,86 hektar) "uygun olmayan alan" olarak sınıflandırılmıştır. Çalışma alanının %2,02'si (4.549,99 hektar) "az uygun alan", %1,99'u (4.492,81 hektar) "uygun alan" ve yalnızca %0,05'i (123,73 hektar) "çok uygun alan" olarak belirlenmiştir (Tablo 5).

Tablo 5. En uygun okul yer seçimi

Uygunluk Durumu	Alan (Ha)	Yüzde (%)
Uygun Değil	216178.86	95.93
Az Uygun	4549.99	2.02
Uygun	4492.81	1.99
Çok Uygun	123.73	0.05
Toplam	225345.40	100.00

Çalışma alanı olarak seçilen Elazığ Merkez İlçesi'nde, yapım süreci devam eden okulların dışında toplam 254 mevcut okul bulunmaktadır. Bu okulların uygunluk durumu, en uygun okul yer seçimi analizi sonucunda oluşturulan sonuç haritası üzerinden değerlendirilmiştir.

Kaynaklar

- AbdulHasan, M., Hanafiah, M., Satchet, M., Abdulaali, H., Toriman, M., & Al-Raad, A. (2019). Combining GIS, fuzzy logic, and AHP models for solid waste disposal site selection in Nasiriyah, Iraq. *Applied Ecology and Environmental Research*, 17(3), 6701–6722. https://doi.org/10.15666/aeer/1703_67016722
- Abera, Y. G. (2019). *Use of multi-criteria decision analysis integrated with GIS and air pollution model inputs for schools site selection* [Master's thesis, University of KwaZulu-Natal]. <https://researchspace.ukzn.ac.za/handle/10413/16702>
- Ahmed Ali, K. (2018). Multi-criteria decision analysis for primary school site selection in Al-Mahaweel district using GIS technique. *Journal of Kerbala University*, 14(1), 342–350.
- Akdemir, A. (2019). *Alışveriş merkezleri için CBS tabanlı en uygun yer seçimi analizi: Üsküdar ilçesi örneği* [Yüksek lisans tezi, Afyon Kocatepe Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Akıncı, H., Yavuz Özalp, A., & Turgut, B. (2013). Agricultural land use suitability analysis using GIS and AHP technique. *Computers and Electronics in Agriculture*, 97, 71–82.
- Akıncı, H., Yavuz Özalp, A., & Temuçin Kılıçer, S., (2015). Coğrafi Bilgi Sistemleri ve AHP Yöntemi Kullanılarak Planlı Alanlarda Heyelan Duyarlılığının Değerlendirilmesi: Artvin Örneği. *Doğal Afetler ve Çevre Dergisi*, 1(1-2), 40–53.
- Akıncı, H., Yavuz Özalp, A., & Özalp, M. (2017). Investigating impacts of large dams on agricultural lands and determining alternative arable areas using GIS and AHP in Artvin, Turkey. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 5(1), 83–95.
- Baffoe, G. (2019). Exploring the utility of analytic hierarchy process (AHP) in ranking livelihood activities for effective and sustainable rural development interventions in developing countries. *Evaluation and Program Planning*, 72, 197–204. <https://doi.org/10.1016/j.evalprogplan.2018.10.017>
- Balca, Y. (2007). *Düzenli depolama alanı belirlemede karar destek sistemi kullanımı* (Yüksek lisans tezi, İstanbul Teknik Üniversitesi). YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Başegmez, M., Taşdemir, İ., & Gül, Ç. (2017, 3-6 Mayıs). *Eğitim alanlarının yer seçim kriterlerinin belirlenmesinde yaşanan problemler ve çözüm önerileri* [Bildiri sunumu]. TMMOB Harita ve Kadastro Mühendisleri Odası, 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara, Türkiye.
- Başegmez, M. (2019). *Çok kriterli karar verme yöntemi ve coğrafi bilgi sistemleri kullanılarak en uygun okul yerlerinin belirlenmesi: Uşak ili merkez ilçe örneği* [Yüksek lisans tezi, Karadeniz Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Bukhari, Z., Rodzi, A. M., & Noordin, A. (2012). Spatial multi-criteria decision analysis for safe school site selection. *International Geoinformatics Research and Development Journal*, 1(2), 1–14.
- Dadfar, N. A. (2014). *Suitability analysis of a new high school in the city of Calabasas* [Master's thesis, California State University]. ScholarWorks. <https://scholarworks.calstate.edu/concern/theses/4f16c5970>
- Dawami, M., Fathoni, M., & Cindarbumi, F. (2022). Application of analytical hierarchy process method as a decision support system in the recruitment of lecturers at Universitas Nahdlatul Ulama Sunan Giri. *Barekeng Jurnal Ilmu Matematika Dan Terapan*, 16(4), 1477–1486. <https://doi.org/10.30598/barekengvol16iss4pp1477-1486>
- Güler, D., & Yomraloğlu, T. (2020). Suitable location selection for the electric vehicle fast charging station with AHP and fuzzy AHP methods using GIS. *Annals of GIS*, 26(2), 169–189.
- Haji, E., Azmani, A., & Harzli, M. (2017). Using AHP method for educational and vocational guidance. *International Journal of Information Technology and Computer Science*, 9(1), 9–17. <https://doi.org/10.5815/ijitcs.2017.01.02>
- Karabıçak, Ç., Boyacı, A. İ., Akay, M. K., & Özcan, B. (2016). Çok kriterli karar verme yöntemleri ve karayolu şantiye yeri seçimine ilişkin bir uygulama. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 13(3), 106–121.
- Kayalık, M., & Polat, Z. A. (2023a). CBS tabanlı nominal değerlendirme yönteminin değer haritalarının oluşturulmasında kullanımı: Foça/İzmir örneği. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(1), 183–192.
- Kayalık, M., & Polat, Z. A. (2023b). CBS destekli nominal taşınmaz değer haritasının 3 boyutlu sunumu: Berlin Eyaleti örneği. *Geomatik*, 8(2), 180–191. <https://doi.org/10.29128/geomatik.1178599>
- Keleş, N. (2022). Okul yeri seçiminde kullanılan kriterlerin analitik hiyerarşi prosesi yöntemiyle önemlerinin belirlenmesi. *Artuklu Kaime Uluslararası İktisadi ve İdari Araştırmalar Dergisi*, 135–154.
- Kent, S. (2014). *İnşaat sektöründe AHP (Analytic Hierarchy Process) yöntemiyle malzeme tedarik zinciri yönetimi* [Yüksek lisans tezi, Eskişehir Osmangazi Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Kılıç, A. K. (2019). *Analitik hiyerarşi süreci (AHS) ve veri zarflama analizi (VZA) yöntemlerinin birlikte kullanımı: OECD ülkelerinin eğitim performansları üzerine bir uygulama* [Yüksek lisans tezi, Pamukkale Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Kuru, A., & Terzi, F. (2018). Determination of new development area in Kırklareli by GIS-based weighted overlay analysis. *International Journal of Environment and Geoinformatics*, 5(3), 244–259. <https://doi.org/10.30897/ijegeo.427330>
- Malczewski, J. (2006). GIS-based multicriteria decision analysis: A survey of the literature. *International Journal of Geographical Information Science*, 20(7), 703–726.

- Mamat, A., Rasid, N., Ahmad, F., Rawi, N., Mohamed, M., Awang, W., ... & Ghazali, F. (2017, October 21). *Pre-school selection system using analytic hierarchy process (AHP): Implementation and usability study* [Conference presentation]. IEEE International Conference on Advances in Computing, Communications and Informatics (ICACCI), Kota Kinabalu, Malaysia.
- Mondal, S., & Mukherjee, J. (2016). A fuzzy analytical hierarchy process in innovative education - An approach. *International Journal of Computer Applications*, 150(9), 47–52. <https://doi.org/10.5120/ijca2016911637>
- Myers, J. H., & Alpert, M. I. (1968). Determinant buying attitudes: Meaning and measurement. *Journal of Marketing*, 32(4), 13-20. <https://doi.org/10.2307/1249333>
- Öztürk, D., & Batuk, F. (2007). Çok sayıda kriter ile karar vermede kriter ağırlıkları. *Yıldız Teknik Üniversitesi Sigma Mühendislik ve Fen Bilimleri Dergisi*, 25(1), 86–98.
- Polat, Z. A., Alkan, M., & Sürmeneli, H. G. (2017). Determining strategies for the cadastre 2034 vision using an AHP-based SWOT analysis: A case study for the Turkish cadastral and land administration system. *Land Use Policy*, 67, 151–166.
- Qubaisi, A., Badri, M., Mohaidat, J., Dhaheri, H., Guang, Y., Rashedi, A., ... & Greer, K. (2016). An analytic hierarchy process for school quality and inspection. *International Journal of Educational Management*, 30(3), 437–459.
- Samad, A. M., Hifni, N. A., Ghazali, R., Hashim, K. A., Disa, N. M., & Mahmud, S. (2012, March 23–25). *A study on school location suitability using AHP in GIS approach* [Conference presentation]. 2012 IEEE 8th International Colloquium on Signal Processing and its Applications, Malacca, Malaysia.
- Shi, L. (2012). Evaluation method for students' grade statistics system based on fuzzy analytic hierarchy process. *Advanced Materials Research*, 433–440, 5339-5343.
- Smith, C., & Bayazit, O. (2020, December 3–6). *Applying the analytic hierarchy process in faculty search* [Symposium presentation]. International Symposium on the Analytic Hierarchy Process (ISAHP). <https://doi.org/10.13033/isahp.y2020.021>
- Talam, P. K., & Ngigi, M. M. (2015, May 6–8). *Integration of GIS and multicriteria evaluation for school site selection - A case study of Belgut Constituency* [Conference presentation]. Sustainable Research and Innovation (SRI) Conference, Nairobi, Kenya.
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234–281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5)
- Saaty, T. L. (1980). *The analytic hierarchy process: Planning, priority setting, resource allocation*. McGraw-Hill.
- Uslu, A., Kızıloğlu, K., İşleyen, S. K., & Kahya, E. (2017). Okul yeri seçiminde coğrafi bilgi sistemine dayalı AHP-TOPSIS yaklaşımı: Ankara ili örneği. *Politeknik Dergisi*, 20(4), 933-943.
- Ünaldık, S. B. (2019). Çok kriterli karar verme yöntemi ile yer seçimi kararında coğrafi bilgi sistemlerinin kullanımı. *Yapı Bilgi Modelleme*, 1(2), 46–52.
- Wang, X., & Peng, X. (2011, May 13–15). *Application of analytic hierarchy process in evaluating education equipment efficiency factors* [Conference presentation]. International Conference on Business Management and Electronic Information (ICBMEI), Guangzhou, China.
- Wang, X., Li, G., Tu, J., Khuyên, N., & Chang, C. (2021). Sustainable education using new communication technology: Assessment with analytical hierarchy process (AHP). *Sustainability*, 13(17), Article 9640. <https://doi.org/10.3390/su13179640>
- Yılmaz, O. S. (2022). Flood hazard susceptibility areas mapping using Analytical Hierarchical Process (AHP), Frequency Ratio (FR), and AHP-FR ensemble based on Geographic Information Systems (GIS): A case study for Kastamonu, Türkiye. *Acta Geophysica*, 70(6), 2747–2769.
- Yücel, U. (2015). *Atıksu arıtma tesisleri için uygun alanların CBS destekli çok ölçütlü karar analizi yöntemi ile belirlenmesi* [Yüksek lisans tezi, Fen Bilimleri Enstitüsü]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Zor, K. (2020). *Denizli ili ilköğretim ve ortaöğretim okul binalarının yer seçimi* [Yüksek lisans tezi, Pamukkale Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>

Orman Yangın Alanlarında Arazi ve Toprak Örtüsündeki Değişimlerin İzlenmesi

Monitoring Changes in Land and Soil Cover in Forest Fire Areas

Betül Kırımlıoğlu^{1*}, Esra Tunç Görmüş¹

¹Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Betül Kırımlıoğlu
betulkrmlglu@gmail.com

doi: 10.48123/rsgis.1603928

Yayın süreci

Geliş tarihi: 19.12.2024
Kabul tarihi: 01.03.2025
Basım tarihi: 26.03.2025

Özet

Ormanlar, dünyamızın en büyük doğal zenginliklerinden biri olup ekosistemin dengesinde önemli bir rol oynamaktadır. Uzaktan algılama teknolojilerinin gelişmesiyle orman yangınının yol açtığı hasar ve buna bağlı olarak meydana gelen zamansal değişimler daha hızlı ve etkili bir şekilde izlenebilmektedir. Bu çalışmada 2019 Haziran ile 2020 Mayıs tarihleri arasında gerçekleşen Avustralya orman yangınından en çok etkilenen Sidney şehrinde yanmış alan seçilmiştir. Yangın öncesi ve sonrası Landsat 8 uydu görüntüleri kullanılarak kontrollü sınıflandırma işlemi ile hasar tespiti yapılmış ve farklı bantların yangın hasarını belirlemedeki etkinliği eşik yöntemleri (Otsu, Tsai, Kapur, Kittler) kullanılarak incelenmiştir. Bunun yanı sıra Yanmış Alan İndeksi (BAI), arazi örtüsünde (NDVI, NDMI, NDBI, EVI, LAI, SAVI) toprak örtüsünde (BSI, LST, SMI, SSI) ve topraktaki mineraller (CM, IOR, FM, Fe⁺³, Fe⁺²) üzerindeki etkisi de detaylı bir şekilde incelenmiştir. Sonuç olarak, yangının ciddi zarar verdiğini, bitkilerin yok olmasıyla çıplak toprak örtüsünün ortaya çıktığını ve arazi yüzey sıcaklığının arttığı gözlemlenmiştir. Bu durum, toprak nem oranının ve tuzluluğunun azalmasına sebep olmuştur. Bitkilerin yeniden canlanmasında önemli bir etken olan demir seviyesinde yangından sonra artış yaşanmıştır. Bu çalışma, yangının etkilerini ve doğanın kendini yenileme sürecinin uzaktan algılama yöntemleri ile başarılı bir şekilde izlenebileceğini göstermektedir.

Anahtar kelimeler: Orman yangını, Uzaktan algılama, Hasar tespiti, Arazi ve toprak örtüsü indeksleri, Zamansal değişim

Abstract

Forests are among the world's greatest natural resources and play a vital role in maintaining ecosystem balance. With the development of remote sensing technologies, the damage caused by forest fires and the temporal changes that follow can be monitored more quickly and effectively. In this study, a region in the city of Sydney, which was most affected by the Australian bushfire between June 2019 and May 2020, was selected. Damage detection was performed using Landsat 8 satellite images before and after the fire through a supervised classification process, and the effectiveness of different bands in determining fire damage was examined using threshold methods (Otsu, Tsai, Kapur, Kittler). In addition, the effect of fire on Burned Area Index (BAI), land cover (NDVI, NDMI, NDBI, EVI, LAI, SAVI), soil cover (BSI, LST, SMI, SSI) and soil minerals (CM, IOR, FM, Fe⁺³, Fe⁺²) were also studied in detail. The results showed that the fire caused serious damage, with the destruction of vegetation resulting in the appearance of bare soil and an increase in land surface temperature. This resulted in a decrease in soil moisture content and salinity. After the fire, an increase in iron levels, which is a crucial factor in plant regeneration, was observed. This study demonstrates the effects of fire and the process of regeneration of nature.

Keywords: Forest fire, Remote sensing, Damage assessment, Land and soil cover indices, Temporal changes

1. Giriş

Ormanlar, dünyamızdaki en önemli ekosistemlerden biridir. Orman, ağaçlar, bitki, hayvan ve hatta toprakta gözle görünmeyen organizmalarla birlikte cansız çevreyle karşılıklı olarak etkileşimde bulunmaktadır (Sabuncu & Özener, 2019). Fakat son yıllarda artan orman yangınları, ağaçlara, bitki örtüsüne, toprağa ve birçok canlıya ciddi zarar vermektedir (Yılmaz vd., 2022).

Büyük orman yangınları hakkında yapılan birçok araştırma da iklim değişikliğinin ve artan sıcaklıkların etkisinin yangın ve iklim üzerindeki ilişkisi ele alınmıştır. Bu araştırmalar sonucunda, iklim değişikliğiyle artan atmosferik kararsızlık, sıcaklığın yükselmesi, kuraklığın artması, sürekli olarak artan sıcaklık dalgaları gibi meteorolojik ve iklimsel koşullar ile ihmal ve dikkatsizlikler birleştiğinde yangınların sayısında ve bıraktığı hasarda ciddi artışa sebebiyet vermiştir (Yıldız & Özgüler, 2021).

Yapılan incelemeler, orman yangınlarını etkileyen üç ana bileşenin sıcaklık, nem ve rüzgâr olduğunu göstermektedir. İklim değişikliğinin bu faktörler üzerindeki etkisiyle birlikte, orman yangınları sonucunda toprağın bitki gelişimi için elverişsiz hâle gelebileceği ve orman alanlarının kaybedilebileceği belirtilmektedir. Ayrıca, sıcaklıktaki küçük farklılıkların bile orman yangınlarında istatistiksel olarak anlamlı bir artışa neden olduğu saptanmıştır (Canlı, 2010).

Yapılan araştırmalar ve çalışmalar sonucunda orman yangınlarından sonra toprak yüzeyindeki kimyasal element miktarında bir artışın meydana geldiğini ve bu artışın gerçekleşen yağışlarla birlikte su kaynaklarına yansıdığı gözlemlenmiştir (Aydın vd., 2017).

Yangından sonra, özellikle üst toprakta su tutma kapasitesinin bir miktar azaldığı saptanmıştır. Bunun nedeni ise toprak üzerindeki ölü örtü tabakasının yok olması ve üst topraktaki humus ile organik maddelerin azalmasından dolayı anlaşılmaktadır (Çepel, 1975).

Toprak hakkında yapılan diğer araştırmalarda orman yangınlarının toprak verimliliği ve yapısı üzerinde olumsuz etkiler yarattığını ve bu değişen toprak koşullarının yağmurun zeminden derinlere sızmasını engellediğini göstermektedir. Özellikle yanmış ağaç ve bitkilerin külleri, toprak yüzeyinde geçirimsiz bir tabaka oluşturarak suyun yer altına sızmasını zorlaştırmaktadır. Sonuç olarak, bu durum toprak-su dengesini bozmakta ve erozyonu hızlandırmaktadır (Robichaud, 2000; Rulli & Rosso, 2007).

Orman yangınlarının yıkıcı etkileri olsa da belirli koşullarda toprağa olumlu katkılar sağlayabilmektedir. Organik maddenin mineralizasyonunu hızlandırarak azot, fosfor ve potasyum gibi besin elementlerinin toprağa salınımını artırabilmektedir (Certini, 2005). Ayrıca, kül birikimi nedeniyle toprak pH seviyesi yükselerek bazı bitkiler için besin alımını kolaylaştırmaktadır (Neary vd., 1999). Yangın sonrası toprak yapısının gevşemesi, mikroorganizma faaliyetlerini artırarak bitki kök gelişimini destekleyebilmektedir (Chandler vd., 1983). Her ne kadar kontrolsüz yangınlar toprakta tahribata yol açabilse de doğal yangın rejimleri besin döngüsünü hızlandırarak ekosistem yenilenmesini teşvik edebilmektedir. Ancak bu etkilerin sürdürülebilir olması, yangının şiddetine ve ekosistemin yapısına bağlıdır (Neary vd., 1999).

Orman yangınlarının sebep olduğu zararların iyileşme süreci oldukça zaman alabilmektedir. Yangın sonrası, ormanın alt tabakasındaki bitki örtüsünün ve çalılıkların eski haline gelmesi birkaç yıl sürebilirken, yapraklar, dallar vb. iyileşmesi genellikle 2-5 yıl içinde tamamlanmaktadır (Fernandes & Botelho, 2003). Avustralya'daki 2019-2020 orman yangınlarında ise bitki örtüsünün iyileşme süresi, bazı bölgelerde 5 yıl gibi iken bazı yerlerde ise iyileşme çok daha uzun bir zaman alabileceği düşünülmektedir. Genel olarak, ormanların eski haline dönmesi 5-10 yıl sürebilmektedir. Bu süre, yangının büyüklüğüne ve bölgedeki iklim koşullarına bağlı olarak değişkenlik gösterebilmektedir (Gibbons vd., 2020).

Orman yangınları sonrası, araziden veri toplamak genellikle yanan alanlara ulaşılmasının zor olması, zaman açısından uzun sürmesi ve arazi çalışmalarının maliyetinin yüksek olması nedeni ile yapılmasına engel olan faktörlerdendir. Bu kısıtlamalardan dolayı son yıllarda orman yangını üzerinde çalışmalar, zaman ve maliyet kazancıyla uzaktan algılama teknolojisine yönelmektedir. Veri elde edilmesi ve analiz yapılabilmesi uzaktan algılama uydu görüntüleri ile mümkün kılmaktadır (Algancı vd., 2011).

Literatürde, farklı indekslerin bir arada kullanılmasının, yangın sonrası değişimlerin daha kapsamlı analiz edilmesini sağladığı gösterilmektedir. Yapılan çalışmalarda, birden fazla spektral indeksin kombinasyonunun, yangının bitki örtüsü ve toprak üzerindeki etkilerini belirlemede tek başına kullanılan indekslere kıyasla daha yüksek doğruluk sunduğu belirtilmektedir (Xu vd., 2024; Partheepan vd., 2024). Bu bağlamda, Xu vd. (2024), yüksek zamansal çözünürlüklü uzaktan algılama verileri kullanarak, orman yangınlarının anlık değerlendirilmesi için yeni bir bitki örtüsü indeksi geliştirmiştir. Çalışmada, yangın sonrası bitki sağlığını değerlendirmek için çeşitli spektral indekslerin entegrasyonu sağlanmıştır. Benzer şekilde, Partheepan vd. (2024), orman yangını şiddeti modellenmesi ve gelecekteki eğilimlerin tahmin edilmesi amacıyla çok sayıda spektral indeks ve makine öğrenimini bir araya getirmiştir. Singh vd. (2021) ise, NDVI ve benzeri indeksleri kullanarak orman yangınlarının hava kalitesi üzerindeki etkilerini analiz etmiştir. Bu çalışmalar, yangın sonrası etkilere dair daha doğru ve kapsamlı sonuçlar elde etmek için spektral indekslerin birlikte kullanılmasının önemini ortaya koymaktadır.


Bu çalışmanın literatürdeki diğer çalışmalardan farkı, spektral indekslerin kapsamlı bir şekilde değerlendirilmesi ve çok yönlü analizlerin uygulanmasıdır. Mevcut araştırmada, sadece bitki örtüsü değişiklikleri değil, aynı zamanda toprak nemi, yüzey sıcaklığı ve mineral kompozisyonundaki değişimler de incelenmiştir. Yangının toprak üzerindeki etkileri genellikle sınırlı sayıda indeks kullanılarak değerlendirilirken (De Santis & Chuvieco, 2007), bu çalışmada NDVI, NDMI, BAI, LST, SAVI gibi bir dizi indeksin birlikte kullanılmasıyla yangının etkileri daha geniş bir perspektiften ele alınmıştır. Yangın sonrası etkilerin daha doğru bir şekilde belirlenebilmesi için eşik yöntemleri (Otsu, Tsai, Kapur, Kittler) kullanılarak farklı bantların yangın hasarını tespit etmede önemi vurgulanmaktadır. Ayrıca, çalışmada demir minerali (Fe^{2+}/Fe^{3+}) değişimlerinin incelenmesi, yangın sonrası toprak verimliliği ve ekolojik iyileşme süreçlerine yönelik yeni bulgular sunmaktadır.

Bu yönüyle çalışma, uzaktan algılama araçlarının yalnızca yangın alanlarının tespitine yönelik değil, ekolojik değerlendirmelere de katkı sağladığı vurgulanmaktadır. Uzaktan algılama teknolojilerinin orman yangını etkilerini izleme ve değerlendirme süreçlerinde nasıl etkin bir şekilde kullanılabileceğini ortaya koyarak, yangın sonrası iyileşme sürecine dair yeni perspektifler sunmaktadır. Ayrıca ormanların kaybettiği bitki örtüsünün yeniden canlanması için geçen sürenin belirlenmesi ve yangından sonra topraktaki değişime bağlı olarak yangına dayanıklı bitkilerin ekilmesi gerektiği konusunda daha bilinçli kararlar alınmasına yardımcı alınabilmektedir.

2. Materyal ve Yöntem


2.1 Çalışma Alanı

Avustralya'da orman yangınları, Haziran 2019 tarihinden başlayarak yaklaşık 8 ay süren yangın Avustralya'nın birçok bölgesini etkisi altına almış ve "Kara Yaz" (Black Summer) olarak tarihe geçmiştir. Bu felakette 24 milyon hektar alan yok olmuş, 3 bin 500 ev yanmış, çok sayıda hayvan can vermiş ve 479 kişi hayatını kaybetmiştir. Bu yangınlar, son on yılın en büyük orman yangınları olarak kaydedilmiştir (Anadolu Ajansı, 2023). Çalışma alanı olarak, orman yangınında en çok etkilenen Sidney şehrindeki yanan alanlar seçilmiştir. Sidney şehrinde $33^{\circ} 5' - 34^{\circ}$ Güney enlemleri, $150^{\circ} - 151^{\circ}$ Doğu boylamları arasında yer alan bölge üzerinde çalışılmıştır. Landsat 8 uydu görüntülerinden yangın öncesi için 10.09.2019, yangın anı için 31.12.2019, yangın sonrası görüntülerde 21.04.2020, 27.08.2020, 14.10.2020, 24.04.2021 tarihleri veri olarak alınmıştır. Görüntülerdeki bulut ve hava şartlarının kötü olmasından dolayı bu tarihler kullanılmıştır.



Şekil 1. Avustralya orman yangını Sidney bölgesi çalışma alanı

Landsat 8 uydusu ile çalışma alanının yangın öncesi, yangın anı ve yangın sonrası görüntüler Şekil 2'de gösterilmiştir.



Şekil 2. Çalışma alanı Landsat 8 uydu görüntüleri: a) yangın öncesi 10.09.2019, b) yangın anı 15.12.2019, c) yangın sonrası 21.04.2020, d) yangın sonrası 27.08.2020, e) yangın sonrası 14.10.2020, f) yangın sonrası 24.04.2021

2.2 Veri Seti

Landsat 8 NASA'nın uydusu olup, yiyecek, su ve ormanlar gibi insan geçim kaynakları için gerekli kaynakların düzenlenmesi, izlenmesi ve anlaşılmasında en önemli rolünün devam etmesi sağlanmıştır. Landsat 8 uydusu, görünür, yakın-kızılötesi, kısa dalga kızılötesi ve termal kızılötesi aralıklarında görüntü üretip spektral aralığa bağlı olarak 15 ile 100 metre arasında uzamsal çözünürlüğe sahiptir (NİK Sistem, 2020). Tablo 1 'de Landsat 8'e ait bantların dalga boyu aralığı ve çözünürlükleri verilmiştir. OLI (Operational Land Imager) sensöründe 9 bant bulunmaktadır. TIRS (Thermal Infrared Sensor) sensörü ise iki adet termal bantta sahiptir (NİK Sistem, 2020).


Tablo 1. Landsat 8 uydu görüntüsünün bant özellikleri

Bantlar	Dalga Boyu (μm)	Konumsal Çözünürlük(m)	OLI/TIRS
Bant 1- Kıyı aerosolü	0.43-0.45	30	OLI
Bant 2- Mavi	0.45-0.51	30	OLI
Bant 3-Yeşil	0.53-0.59	30	OLI
Bant 4-Kırmızı	0.64-0.67	30	OLI
Bant 5- Yakın kızılötesi	0.85-0.88	30	OLI
Bant 6- Kısa dalga boylu kızılötesi	1.57-1.65	30	OLI
Bant 7- Kısa dalga boylu kızılötesi	2.11-2.19	30	OLI
Bant 8- Pankromatik	0.50-0.68	15	OLI
Bant 9- Sırrus	1.36-1.38	30	OLI
Bant 10- Uzun dalga boylu kızılötesi	10.60-11.19	100	TIRS
Bant 11- Uzun dalga boylu kızılötesi	11.50-12.51	100	TIRS

2.3 Metodoloji

Bu çalışmada Landsat 8 uydusu kullanılarak görüntülere ön işleme olarak ENVI 5.2 Programıyla önce radyometrik düzeltme sonra atmosferik düzeltme işlemi yapılmıştır. Çalışma alanı için yanan ormanlar, su kaynakları ve şehir merkezini kapsayacak şekilde geniş bir alan sınırları kesilmiştir. Çalışma iki ana kısımdan oluşmaktadır.

Birinci kısımda hasar tespit çalışması ve değişim analizi yapılmıştır. Hasar tespiti için, ENVI 5.2 Programı kullanılarak yangın sonrası görüntüsüne kontrollü sınıflandırma yöntemi olan Maximum Likelihood uygulanmıştır. Doğruluk analizi yapıldıktan sonra hasar tespitine geçilmiştir. Sonrasında Maximum Likelihood yöntemi ile Normalleştirilmiş Yanma Oranı (NBR) arasında karşılaştırma yapılmıştır. Bu karşılaştırma iki farklı yöntemin yanan alanları tespit etmesinde başarılı ve benzer olduğu üzerine yapılmıştır. Değişim analizi ise, Landsat 8 uydu görüntülerinin multispektral bantları üzerinden ne gibi farklılıklar yaşandığını gözlemlemek için yapılmıştır. Bu farklılıkların tespit edilmesi, ikinci kısımda spektral indekslerin kullanılmasında ve değişimin yorumlanmasında rol almıştır. ENVI 5.2 Programında 'Image Change Workflow' üzerinden yangın öncesi (10.09.2020) ve yangın sonrası (21.04.2020) görüntüleri kullanılarak bu değişime bakılmıştır. Eşik değer yöntemlerinden Otsu, Tsai, Kapur ve Kittler yöntemleri ile hangi bantların yangından daha çok etkilendiği tespit edilmiştir. İkinci kısımda ise arazi bitki ve toprak örtüsündeki değişim için spektral indeksler kullanılarak hem yangından önce hem de yangından sonraki görüntülerde zamansal değişim nicel ve nitel olarak incelenmiştir. Yangın alanının zamanla uğradığı değişim için yangından sonraki görüntüye Yanmış Alan İndeksi (BAI) uygulanmıştır. Arazi bitki örtüsündeki değişim için yangından önceki ve sonraki görüntüler üzerinden Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), Normalleştirilmiş Fark Nem İndeksi (NDMI), Normalleştirilmiş Fark Yerleşim Alanı İndeksi (NDBI), Gelişmiş Bitki Örtüsü İndeksi (EVI) ve Yaprak Alan İndeksi (LAI), Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI) kullanılmıştır. Toprak örtüsündeki değişim için görüntülere Çıplak Toprak İndeksi (BSI), Arazi Yüzey Sıcaklığı (LST), Toprak Nem indeksi (SMI) ve Toprak Tuzluluğu İndeksi (SSI) bakılmıştır. Toprak mineralleri için Kil Minerali (CM), Demir Minerali (FM), Ferröz (Fe^{+2}), Ferrik (Fe^{+3}) ve Demir Oksit (Fe_2O_3) Oranı (IOR) değerleri için de indeksler kullanılmıştır. Bu değişimler sonucunda orman yangınlarının Landsat 8 uydu görüntüleri ile etkileşimi incelenmiştir. Arazi örtüsündeki değişim gözlenmiş ve önceden yapılmış laboratuvar sonuçları ile benzer yönde değişim olup olmadığı incelenmiştir. Bu çalışmada izlenen metodoloji Şekil 3'te verilmiştir. Aşağıdaki alt başlıklarda bu adımları daha detaylı bir şekilde anlatılmaktadır.



Şekil 3. Çalışmada izlenen metodoloji

2.3.1 Hasar Tespit Çalışması ve Değişim analizi

Hasar tespiti amacıyla çalışma alanına ait yangından sonraki 24.04.2020 tarihli Landsat 8 uydu görüntüsüne kontrollü sınıflandırma yöntemi olan Maximum Likelihood uygulanmıştır. Yüzey örtüsünün daha kolay belirlenmesi amacıyla Su alanı, Orman alanı, Yerleşim alanı, Yanmış alan ve Arazi olmak üzere 5 sınıf belirlenmiştir. Normalleştirilmiş Yanma Oranı İndeksi (NBR) ile sonuçlar karşılaştırılmıştır. Orman yangınlarının etkisini değerlendirmek ve yanan alanları belirlemek için kullanılan bir indekstir. Bu indeks, bitki örtüsünün sağlığını ve yangın sonrası hasarın derecesini ölçmek için yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantlarını kullanır (Key & Benson, 2006).

2.3.2 Eşik Değer Yöntemleri

Bu çalışmada Otsu, Kapur, Tsai, Kittler adında 4 farklı eşik değer yöntemi kullanılarak yangının Landsat 8 bantları üzerindeki etkisi ayrı ayrı incelenmiştir. Sonuçları Tablo 2'de nicel olarak verilmiştir. Eşik değer yöntemlerinden en eski

bilinen Otsu, histogram tabanlı eşikleme yöntemlerindedir. Nesne ve arka plan pikselleri olmak üzere iki sınıfa ayırarak tek bir yoğunluk eşiğine döndürür (Otsu, 1979). Kapur Yöntemi, nesne ve arka planı piksellerin toplam entropisini en büyük yapacak eşik değerini optimum hale getirmektedir (Kapur vd., 1985; Sezgin, 2002).

Otsu yönteminde sınıflar arasındaki varyans dikkate alınırken, Kapur yönteminde ise sınıflar arasındaki entropi değerleri dikkate alınır (Demirci vd., 2014; Kılıçaslan, 2018). Tsai, nesne tabanlı bir yöntemdir. Orijinal görüntü ile ikili görüntü arasındaki özellik veya benzerlik ölçüsüne bakılarak eşik değeri bulunmaktadır (Tsai, 1985). Kittler Yöntemi histogram şekline dayalı bir yöntemdir. Histograma iki modlu bir Gauss dağılımı olarak yaklaşır ve bir kesme noktası bulur (Kittler vd. 1986).

Çalışmada yangın sonrası (21.04.2019) görüntü ile yangın öncesi (10.09.2019) görüntüsünün karşılıklı multispektral bantları seçilerek bu işlem gerçekleştirilmiştir. Otsu, Tsai, Kapur ve Kittler yöntemleri ile bu işlem her bir bant için yapılmıştır. Birden fazla yöntemin kullanılmasının sebebi analizin doğruluğunu arttırmak ve bu sayede yangının hangi multispektral bant üzerinde etkisinin olduğu daha iyi anlaşılması sağlanmıştır. ENVI 5.2 programı toolbox içerisinde 'Image Change Workflow' ile bu çalışma yapılmıştır. 'Image Difference' sonrasında 'Difference of Input Band' seçeneği basılarak sırayla bantlar seçilmiştir. 'Auto-Thresholding Method' dört farklı seçenek ile değişim analizi yapılmıştır.

2.3.3 Kullanılan Spektral İndeksler

Bu çalışmada 17 farklı arazi, bitki, toprak ve mineral indeksleri kullanılmıştır. Bu indekslerin, orman yangınının bitkiler ve toprak üzerindeki tahribi ve zamansal etkilerinin belirlenmesi amacıyla yapılmıştır. Bitkiler üzerinde birçok indekse bakılarak paralel sonuçlar elde edilip edilmediğine bakılmak istenmiştir. Bunlar kısaca aşağıda formülleri ile açıklanmıştır.

Yanmış alan indeksi (BAI) yangın sonrası görüntülerdeki korlanmış kömür sinyalinin vurgulayıp, kırmızı ve yakın kızıl ötesi dalga boyundaki bantlar Tablo 2'deki formülle yanmış alanı ortaya çıkarır. BAI analizi kullanılarak, yangın sonrası süreçte zamansal olarak yanmış alanda azalma olup olmadığına değeri incelenmek istenmiştir (Chuvieco vd., 2002).

Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), yakın kızılötesi (NIR) ve kırmızı bantlar (Red) arasındaki zıtlığı artırır ve iki banttaki bilgileri tek bantta toplayarak, bitki varlığının ve sağlığının incelemesinde kullanılmaktadır (Kayman, 2015). NDVI, (-1) ile (+1) arasında değişen aralıkta değer vermektedir. Bitki varlığı yoğun olduğu bölgelerde NDVI + 1'e yaklaşır, bitki örtüsünün azalmasıyla sıfıra yaklaşmaktadır. Bulut, su ve kar gibi nesnelere olduğu alanlarda NDVI indeks değerleri ise -1'e yakındır (Hatfield, 1985; Yıldız vd., 2012).

Normalleştirilmiş Fark Nem İndeksi (NDMI), bitki örtüsündeki nem seviyelerine duyarlı indekstir. NIR ve SWIR bantlarını kullanır ve değerler (-1) ile (+1) arasında değişir (Gao, 1996). Yeşil bitki örtüsü için ortak aralık -0,1 ile 0,4'tür. -1 ile 0, bitki örtüsü veya su içeriği olmayan parlak yüzey, +1 ise su içeriğini temsil eder. 0,3'ten az olan bölgeler susuz, 0,3 ve daha fazla değer de olan bölgeler ise su varlığı verir (EOS Data Analytics Inc, 2020).

Normalleştirilmiş Fark Yerleşim Alanı İndeksi (NDBI) yerleşim alanlarını analiz eder. SWIR ve NIR bantları kullanılır. Negatif değerler bitki varlığının olmadığı alanları vermektedir (Zha vd., 2003). NDBI uygulanmış görüntülerde (-1) ile (+1) arasında değer almaktadır (Zha vd., 2003; Pashaei & Aksoy, 2022).

Gelişmiş bitki örtüsü indeksi (EVI), bitki örtüsü ve sağlığı hakkında bilgi verir. Değer aralığı (-1) ile (+1) olan indekste eksi yöne doğru bitki varlığının ve sağlığının azaldığını, 1'e doğru gittikçe arttığını temsil eder (Huete vd., 2002).

LAI yaprak alanlarının belirlenmesini ölçmek için kullanılan en uygun indekstir. Bitki örtüsü, büyümesini ve verimi hakkında bilgi vermektedir. Yüksek LAI değerleri genellikle (0) ile (3.5) arasında olmaktadır (Boegh vd., 2002). Gelişmiş bitki örtüsü indeksi kullanılarak Tablo 2'de formülle sonuç elde edilir.

Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI), düzeltme faktörü ile toprak parlaklığının etkisini azaltır. NIR ve Red bantları kullanılır. Bitki varlığının az olduğu alanlarda daha iyi sonuç vermektedir. SAVI indeksi (-1) ile (+1) arasındaki değerleri verir. 1 değerine doğru yaklaştıkça bitki ve sağlıklı bitki varlığını, -1'e doğru yaklaştıkça toprak varlığını temsil eder (Huete, 1988; Yüksel, 2022).

Çıplak Toprak İndeksi (BSI), yakın kızılötesi, kısa dalga kızılötesi, mavi ve kırmızı bantları kullanarak denklem 8'deki formülle elde edilir. SWIR ve Red bantları toprak minerallerini, Blue ve NIR bantları ise bitki örtüsünün varlığını ölçmek için kullanılır (Chen vd., 2004).

Özellikle kuru toprak parlaktır, ıslak toprak kuru topraktan daha karanlıktır, Toprağın Kırmızı banttaki yansımaları düşüktür. (-1) ile (+1) arasında değer almaktadır. -1'e doğru değer koyu renk iken 1'e doğru değeri parlak renk olarak yansımaktadır.

Arazi Yüze Sıcaklığı (LST) kullanılarak orman alanlarındaki öncesi ve sonrası yüze sıcaklığı hakkında bilgi edinebilmektedir. Bu çalışmada yüze sıcaklığının belirlenmesi için Yeryüzü Yüze Sıcaklığı algoritması Landsat 8 için yeniden uyarlanarak kullanılmıştır. Bu işlemler yapılırken öncelikle görüntülere 'radiometric calibration' üzerinden ToA parlaklığının (L_a) ve ToA parlaklık sıcaklığının (T_B) dönüşümünü ölçmek için gerekli radyometrik düzeltmeler yapılmıştır. Landsat-8 TIRS verilerinden Tablo 1'de gösterilen 10. ve 11. termal bantları kullanılmıştır. Ardından, doğru LST değerini elde etmek için arazi yüzeyi direncini, NDVI'yi maksimum ve minimum değeri ile hesaplanır. Ardından, P_v ve ε hesaplanmıştır.

LST ise Denklem 9 ile hesaplanır. T değeri parlaklık sıcaklığı değerleri (K), λ değeri yayılan ışınının merkez dalga boyu (μm), ρ değeri $h \cdot c / \sigma$ ($1.438 \cdot 10^{-2} \text{ m} \cdot \text{K}$), ϵ değeri ise yeryüzü yayınlılık değerini temsil etmektedir (Dağlıyar vd., 2015). Çıkan değerlerden, son olarak Toprak Nem İndeksini (SMI) Denklem 10 ile hesaplanır (Khaneghah, 2016).

Toprak tuzluluğu indeksi (SSI) topraktaki tuzluluğun haritalanması için en uygun yöntemdir (Al-Khaier, 2003). (-1) ile (+1) arasında değerler almaktadır. -1 değerine doğru koyu renk, 1 değerine doğru ise açık parlak renk olarak görüntüye yansır. Parlak renk ve yüksek değer, yüksek tuz içeriğini, koyu renk ve düşük değer, düşük tuz içeriğini gösterir (Ghazali vd., 2019).

Mineraller toprağın fiziksel özelliklerinden nem, organik madde miktarı, ana materyalin cinsi yangınlarda büyük rol oynamaktadır (Bilgili, 2014). Kil minerallerinin tipi ve oranı, toprakların özellikleri açısından belirleyici olup, yangınların etkisi için de kritik rol oynamaktadır (Yılmaz, 1984; Aslan vd., 2016). Yüksek yoğunluklu orman yangınları, toprak yüzeyindeki kil minerallerinin miktarını azaltabilmektedir. Yangınlar, topraktaki kil minerallerinin yapısal bozulmasına yol açarak, su tutma kapasitesinde değişiklikler meydana getirebilmektedir. Bu bozulmalar, erozyonun artmasına ve bitki örtüsünün yeniden gelişmesinin zorlaşmasına sebep olabilmektedir (Reynard-Callanan vd., 2010). Kil miktarı, toprak için su tutma ve zenginlik açısından önemlidir (Yılmaz, 1984). Bu araştırmalar doğrultusunda kil mineralinin orman yangınlarında etkilendiği sonucuna varılmıştır.

Kil Mineralleri (CM) oranı yöntemi, iki kısa dalga kızılötesi (SWIR) bandı kullanarak kil ve alunit içeren mineral özelliklerini tanımlamaya yönelik bir jeolojik indekstir. CM, mineral kompozit haritalamada kullanılır. Kil mineraline bakıldığında azalma olması beklenmektedir. İndeks işleminde histogram değerleri 0 ile 5 arasında değer almaktadır. Parlak alanlar yüksek kil miktarını, koyu renkler ise düşük kil miktarını ifade eder (Dogan, 2009).

Demir Minerali (FM) Oranı, SWIR ve NIR bantlarını kullanarak bir miktar demir içeren mineral içeren kaya ve kum özelliklerini tanımlamak için jeolojik bir indekstir. FM, mineral kompozit haritalamada kullanılır (Segal, 1982). Orman yangınından sonra topraktaki minerallerin oranındaki değişim incelenmiştir. Yangından sonra koyu renk alanlar, parlak olarak yansımaya başlamıştır. Demirin azalmasıyla zamanla tekrar koyulaşmaya başlamıştır. Yani değer yükselip sonrasında tekrardan düşmeye başlamıştır.

Demir Oksit (Fe_2O_3) Oranı (IOR), kırmızı ve mavi dalga boyu arasında bantların oranlanması ile ortaya çıkmıştır (Segal, 1982). Demir oksitlerin oluşumunda birçok sayıda reaksiyonla meydana gelmektedir. Demir oksit bir kere oluşuktan sonra başka bir forma dönüşebilir. Bu durum çevre şartlarının değiştiği ya da ilk oluşan mineralin kararlı bir yapıya sahip olmadığı durumlarda görülür (Firo, 2012).

Topraktaki Fe^{2+} ve Fe^{3+} oranlarına bakıldığında yangın sonrası havalanmayan toprak olduğu için aşağıdaki denklem 1'e dayanarak bakılmıştır (Demir, 2009). Landsat 8 uydu görüntüsü kullanılarak bu mineraller de ki değişim incelenmeye çalışılmıştır. Havalanmayan toprakta anaerob bakteriler Ferrik ile etkileşime girerek Ferröz'ü oluşturmaktadır. Fe^{2+} ve Fe^{3+} formülleri (Rowan & Mars, 2003) kullanılarak çıkan sonuçlar denklemler destekler niteliktedir. Bu denklem sonucunda pH artar, toprak profili boyunca Fe miktarı artar (Demir, 2009).




Tablo 2. Kullanılan spektral indeksler ve formülleri

Spektral İndeksler	Formül
Yanma Oranı İndeksi (Key ve Benson, 2006)	$\text{NBR} = (\text{NIR} + \text{SWIR}) / (\text{NIR} - \text{SWIR})$
Yanmış Alan İndeksi (Chuvieco vd., 2002)	$\text{BAI} = 1 / ((0.1 - \text{Red})^2 + (0.06 - \text{NIR})^2)$
Normalleştirilmiş Fark Bitki Örtüsü İndeksi (Rouse vd., 1973)	$\text{NDVI} = (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$
Normalleştirilmiş Fark Nem İndeksi (Gao, 1996)	$\text{NDMI} = (\text{NIR} - \text{SWIR}) / (\text{NIR} + \text{SWIR})$
Normalleştirilmiş Fark Yerleşim Alanı İndeksi (Zha vd., 2003)	$\text{NDBI} = (\text{SWIR} - \text{NIR}) / (\text{SWIR} + \text{NIR})$
Gelişmiş Bitki Örtüsü İndeksi (Huete vd., 1997)	$\text{EVI} = 2.5 * ((\text{NIR} - \text{Red}) / (\text{NIR} + 6 * \text{Red} - 7.5 * \text{Blue} + 1))$
Yaprak Alan İndeksi (Boegh vd., 2002)	$\text{LAI} = (3.618 * \text{EVI} - 0.118)$
Toprak Ayarlı Bitki Örtüsü İndeksi (Huete, 1988)	$\text{SAVI} = (1.5 * (\text{NIR} - \text{Red})) / (\text{NIR} + \text{Red} + 0.5)$
Çıplak Toprak İndeksi (Chen vd., 2004)	$\text{BSI} = [(\text{SWIR} + \text{Red}) - (\text{NIR} + \text{Blue})] / [(\text{SWIR} + \text{Red}) + (\text{NIR} + \text{Blue})]$
Arazi Yüzey Sıcaklığı (Weng vd., 2004)	$\text{LST} = T / (1 + ((\lambda * T) / \rho) * \ln(\epsilon))$
Toprak Nem İndeksi (Wang ve Qu, 2007)	$\text{SMI} = (\text{LST}_{\text{max}} - \text{LST}) / (\text{LST}_{\text{max}} - \text{LST}_{\text{min}})$
Toprak Tuzluluğu İndeksi (Al-Khaier, 2003)	$\text{SSI} = (\text{SWIR1} - \text{SWIR2}) / (\text{SWIR1} + \text{SWIR2})$
Kil Mineralleri Oranı (Hunt, 1977)	$\text{CM} = \text{SWIR1} / \text{SWIR2}$
Demir Minerali Oranı (Segal, 1982)	$\text{FM} = \text{SWIR} / \text{NIR}$
Demir Oksit Oranı (Segal, 1982)	$\text{IOR} = \text{Red} / \text{Blue}$
Fe^{2+} İndeksi (Rowan & Mars, 2003)	$\text{Fe}^{2+} = (\text{SWIR2} / \text{NIR}) + (\text{Green} / \text{Red})$
Fe^{3+} İndeksi (Rowan & Mars, 2003)	$\text{Fe}^{3+} = \text{Red} / \text{Green}$

3. Bulgular ve Tartışma

3.1. Hasar Tespit ve Değişim Analizi Sonuçları

Yangının neden olduğu değişimi belirlemek için 24.04.2020 tarihli Landsat 8 uydu görüntüsüne Maximum Likelihood sınıflandırma yöntemi uygulanmıştır. Su alanı, Orman alanı, Yerleşim alanı, Yanmış alan ve Arazi olmak üzere 5 sınıf belirlenmiş, sonucu Şekil 4(a)'da gösterilmiştir. Görüntüde kırmızı bölgeler yanmış alanı ifade etmektedir. Ayrıca Normalleştirilmiş Yanma Oranı İndeksi (NBR) Şekil 4(b)' de kullanılarak (Lopez vd. 1991) karşılaştırılmıştır. NBR indeksinde siyah alanlar yanmış alanı ifade etmektedir. Kontrollü sınıflandırma ile yakın benzerlik yanmış alanların doğruluğu kanıtlar niteliktedir. Kontrollü sınıflandırma doğruluk analizi için rastgele 300 nokta atılmış ve ENVI 5.2 Programı ile sınıflandırmaya ait hata matrisi, Kappa değeri raporlanmış ve bu rapor doğrultusunda sınıflandırma işlemimizin genel doğruluk %96,12 ve Kappa katsayısı 0,81 olarak hesaplanmıştır. En yüksek doğruluk su alanı sınıfında görülmüş olup, üretici doğruluğu %92,31 ve kullanıcı doğruluğu %90,57'dir. Yanmış alan sınıfı %89,47 üretici doğruluğu ve %92,39 kullanıcı doğruluğu ile yüksek bir performans göstermiştir. En düşük doğruluk ise arazi sınıfında tespit edilmiştir, üretici doğruluğu %62,96 ve kullanıcı doğruluğu %68,00 olmuştur. Hasarlı alan hesabı için yanmış alanın sınıflandırma tablosundaki histogram değeri ile Landsat 8 uydu görüntüsünün konumsal çözünürlük değerinin çarpılmasıyla elde edilmiştir. Konumsal çözünürlük, uydu görüntüsünün bir pikselinin yeryüzündeki alanını, histogram değeri ise o sınıfa ait piksel sayısını ifade etmektedir. Landsat 8 uydu görüntüsünün multispektral bantlarının konumsal çözünürlüğü 30m'dir. Sınıflandırmada yanmış alanı gösteren sınıfın histogram değeri 1.633.123 sonucunu vermiştir. Bu iki değer çarpılarak 146.981.1 ha (hektar) alanın yandığı belirlenmiştir. Orman Alanının büyük ölçüde azaldığı anlaşılmaktadır. Elde edilen bulgular, Demir ve Kıldıl'ın (2020) çalışmasını destekler nitelikte olup, yangın sonrası Maximum Likelihood sınıflandırma yöntemini kullanarak yangın alanlarının belirlenmesinde yüksek doğruluk oranları elde etmiş ve yanmış alanların tespitinde uzaktan algılama yöntemlerinin etkinliğini göstermiştir.



Şekil 4. Yangın sonrası görüntü (24/04/2020): a) kontrollü sınıflandırma sonucu, b) normalleştirilmiş yanma oranı indeksi (NBR) sonucu

3.1. Yangın Öncesi ve Sonrası Bantlardaki Değişim

Bu çalışmada değişim analizi, yangın sonrası görüntüden yangın öncesi görüntüsünün karşılıklı multispektral bantların piksellerinin çıkarma işlemiyle yapılmıştır. Yangının bantlar üzerinde etkisi artış ve azalış oranıyla incelenmek istenmiştir. Birden fazla yöntemin kullanılarak bantlardaki değişimin yöntem değişikçe değişip değişmediğine ve doğruluğuna bakılmıştır. Bu sayede yangının hangi multispektral bant üzerinde etkisi olduğu bulunmaktadır.

Tablo 3. Eşik değer yöntemleri tablosu

Eşik Değer Yöntemi	Bantlar	Büyük Artış (%)	Büyük Azalış (%)	Fark
Otsu's	Bant 1- Kıyı aerosolü	0.031	16.278	-16.247
	Bant 2- Mavi	0.019	13.344	-13.325
	Bant 3- Yeşil	0.015	13.712	-13.697
	Bant 4- Kırmızı	0.012	11.838	-11.826
	Bant 5- Yakın kızılötesi	1.385	26.733	-25.348
	Bant 6- Kısa dalga boylu kızılötesi	3.694	10.911	-7.217
	Bant 7- Kısa dalga boylu kızılötesi	8.513	10.395	-1.882
Tsai's	Bant 1- Kıyı aerosolü	0.044	4.218	-4.174
	Bant 2- Mavi	0.055	6.179	-6.124
	Bant 3- Yeşil	0.070	6.726	-6.656
	Bant 4- Kırmızı	0.109	11.838	-11.729
	Bant 5- Yakın kızılötesi	1.463	24.209	-22.746
	Bant 6- Kısa dalga boylu kızılötesi	0.375	13.235	-12.860
	Bant 7- Kısa dalga boylu kızılötesi	2.798	11.311	-8.522
Kapur's	Bant 1- Kıyı aerosolü	0.006	0.004	-0.002
	Bant 2- Mavi	0.007	0.003	-0.004
	Bant 3- Yeşil	0.006	0.003	-0.003
	Bant 4- Kırmızı	0.007	0.001	-0.006
	Bant 5- Yakın kızılötesi	0.004	0.016	-0.012
	Bant 6- Kısa dalga boylu kızılötesi	0.027	0.001	0.026
	Bant 7- Kısa dalga boylu kızılötesi	0.032	0.002	0.030
Kittler's	Bant 1- Kıyı aerosolü	0.531	16.278	-15.747
	Bant 2- Mavi	2.105	96.780	-94.675
	Bant 3- Yeşil	4.400	93.404	-89.004
	Bant 4- Kırmızı	9.648	86.059	-76.411
	Bant 5- Yakın kızılötesi	7.709	91.786	-84.077
	Bant 6- Kısa dalga boylu kızılötesi	11.238	86.923	-75.685
	Bant 7- Kısa dalga boylu kızılötesi	26.079	70.742	-44.663

Tablo 3'te Otsu's yönteminin sayısal verilerinden yola çıkarak en çok etkilenen bandın Bant-5 yani yakın kızılötesi olduğu anlaşılmıştır. Bitkilerin kızılötesi dalga boyu en çok etkisi bilindiği üzere burada da azalış gösterdiği ortaya çıkmıştır. En çok artış oranı ve en az fark ise 6. ve 7. bantta görülmektedir. SWIR (Kısa dalga Kızılötesi) bantları toprak ve bitki örtüsünde kullanılmaktadır. Bu artışın sebebinin yangının ormansızlaşmaya sebebiyet verdiği için ve ortaya çıplak toprak çıkması bu bantlarda etkilediği anlaşılmaktadır.

Tablo 3'te Tsai's eşik değer yöntemine bakıldığında en çok farkın Bant-5 de olduğu sayısal değerlerle anlaşılmaktadır. Aynı şekilde yangından sonra bitkilerin azalmasından dolayı bandın etkilendiği bu yöntemle de anlaşılmaktadır. Bant-7 de ise büyük artış oranının yüksek olması toprak örtüsünün ortaya çıkmasından dolayı SWIR bandını etkilemiştir.

Kapur's eşik değer yöntemine Tablo 3' te değerlerine bakıldığında Bant-6 ve Bant-7'de artış olduğu görülmektedir. Diğer yöntemler olduğu gibi bu yöntemde de en fazla azalış Bant-5'te olmuştur.

Kittler's eşik değer yönteminde nerdeyse tüm bantlarda Tablo 3' te büyük azalış oranında yüksek sonuçlar çıkmıştır. Bu yöntemde de göze çarpan durumlar bant 6 ve 7 de diğerlerinden farklı olarak büyük artış oranında en yüksektir. Bunun sebebi diğer yöntemlerde de ortaya çıktığı gibi yangın sonrasındaki çıplak toprak görüntüsü olduğundanır.

En büyük azalışta ise Bant-5, Bant-3 ve Bant-2 göze çarpmaktadır. Kızıl ötesi bant dışında bu yöntemde diğer bantlarında yüksek değerler vermesi yeşil alanlardaki azalma ve su oranındaki azalma mavi ve yeşil bantları da etkilemiştir.

Yanan alan ve yanma şiddeti tespiti çalışmalarında, elektromanyetik spektrumun kırmızı (0.63 - 0.69 μm) bölgesinden kısa dalga kızılötesi (2.08 - 2.35 μm) dalga boyuna kadar etkilediği Tonbul (2015) tarafından söylenmiştir. Ayrıca yakın kızılötesi bant ve kısa dalga kızılötesi bandın, yanan alan tespiti ve haritalanmasında en iyi spektral aralığa sahip olduğu ifade edilmiştir. Yakın kızılötesi bant yansıtımı, vejetasyonda meydana gelen azalmaya bağlı olarak yangın sonrası süreçte büyük oranda azalmaktadır (Tonbul, 2015).

3.2. Spektral İndekslerin Uygulanması

Bu çalışmada 7 tane farklı indeks sırasıyla Yanmış Alan İndeksi (BAI), Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), Normalleştirilmiş Fark Nem İndeksi (NDMI), Normalleştirilmiş Fark Yerleşim Alanı İndeksi (NDBI), Gelişmiş Bitki Örtüsü İndeksi (EVI) ve Yaprak Alan İndeksi (LAI), Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI) arazi bitki örtüsündeki değişimi, 9 tane farklı indeksler sırasıyla Çıplak Toprak İndeksi (BSI), Arazi Yüzey Sıcaklığı (LST), Toprak Nem indeksi (SMI) ve Toprak Tuzluluğu İndeksi (SSI), Kil Minerali (CM), Demir Minerali (FM), Ferröz (Fe^{+2}), Ferrik (Fe^{+3}) ve Demir Oksit (Fe_2O_3) Oranı (IOR) toprak örtüsündeki değişimi için kullanılmıştır ve sonuçlar aşağıda nitel ve nicel olarak incelenmiştir. 5 farklı tarihlerden alınmış Landsat 8 uydu görüntülerinden yangın öncesi için 10.09.2019, yangın sonrası için 21.04.2020, 27.08.2020, 14.10.2020, 24.04.2021 verileri kullanılmıştır.

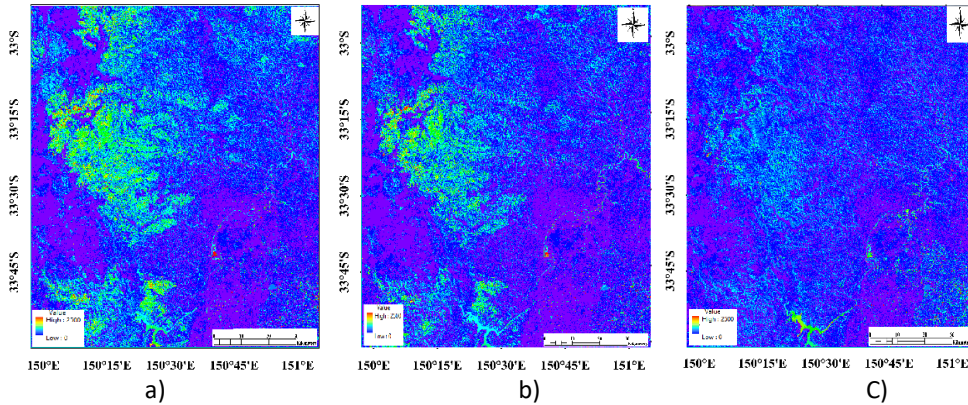
3.3.1 Arazi Bitki Örtüsünün Spektral İndekslerle İncelenmesi

Bu çalışmada, yangın sonrası süreçte yanmış alanlardaki değişimi incelemek amacıyla Yanmış Alan İndeksi (BAI) kullanılmıştır. Yangın sonrası iyileşme sürecini değerlendirmek için 21.04.2020, 27.08.2020, 14.10.2020 ve 24.04.2021 tarihli uydu görüntüleri analiz edilmiştir.

Tablo 4'teki sayısal değerlere göre, zamanla Yanmış Alan İndeksinde belirgin bir azalma olduğu gözlemlenmiş, doğanın kendini 12 ay içinde yenilemeye çalıştığı anlaşılmıştır. Şekil 5'teki BAI uygulanmış görüntüler incelendiğinde, sayısal verilerle uyumlu olarak yeşil ve kırmızı alanların yanmış bölgeleri temsil ettiği görülmektedir. Gibbons vd. (2020) araştırmasına göre, bitki örtüsünün iyileşme süresi bölgeye bağlı olarak değişmekte olup, bazı alanlarda 5 yıl içinde gerçekleşirken bazı yerlerde çok daha uzun sürebilmektedir. Bu çalışmada elde edilen sonuçlar, yangın sonrası tamamen eski haline dönmese de belirli bir iyileşmenin gerçekleştiğini ve bunun zaman gerektirdiğini göstermektedir.

Tablo 4. Yanmış alanı indeksi (BAI) işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
BAI	Yangın Sonrası (21.04.2020)	1.203	2398.639	68.645	258.732
	Yangın Sonrası (27.08.2020)	0.880	1789.036	61.757	230.009
	Yangın Sonrası (14.10.2020)	0.594	1678.490	51.307	198.728
	Yangın Sonrası (24.04.2021)	1.222	1006.876	50.595	180.691

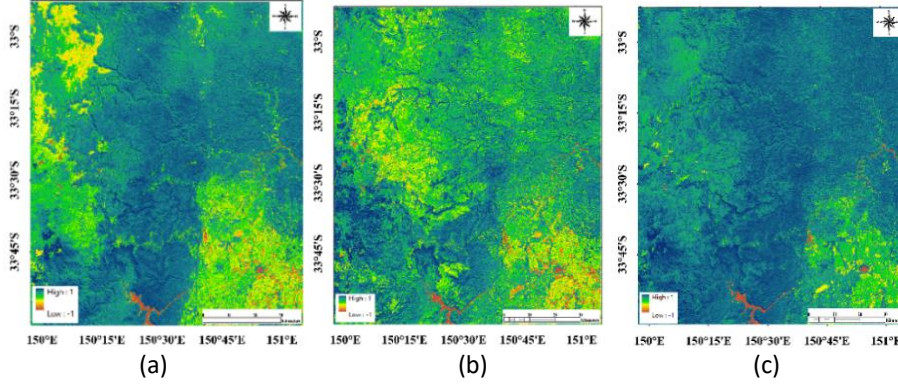


Şekil 5. Yangın sonrası BAI işlemi görüntüleri a) 21.04.2020 b) 27.08.2020 c) 24.04.2021

Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI) değer aralığına Tablo 5'te bakıldığında, yangın sonrası yanan bölgelerde NDVI değerlerinin düştüğü ve bitki örtüsünün azaldığı görülmektedir. Normalde yangın öncesi ve sonrası değerler arasındaki farkın daha belirgin olması beklenirken, mevsim değişimi bu durumu etkilemiştir. Şekil 6'daki görüntülerde NDVI değerleri -1 ile 1 arasında olup, renk skalası kırmızıdan maviye doğru değişmektedir. Yangın öncesinde koyu mavi görülen ormanlık alanlar, yangın sonrası sarı, yeşil ve kırmızı tonlarına dönüşmüştür. Bu da bitki örtüsünün yangından zarar gördüğünü göstermektedir. Zamanla sağlıklı bitkilerin azaldığı ve ekosistemin toparlandığı gözlemlenmiştir. Benzer şekilde, 2021 yılında Mersin'in Silifke ilçesinde yapılan bir çalışmada da yangın sonrası NDVI değerlerinin düştüğü ve bitki örtüsünde belirgin bir azalma olduğu tespit edilmiştir (Çelik vd., 2023). Bu durum, yangın sonrası bitki örtüsündeki hasarın benzer yöntemlerle izlenebildiğini ortaya koymaktadır.

Tablo 5. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI) işlemi değerleri


	Tarih	Min	Maks	Ortama	StdSap
NDVI	Yangın Öncesi (10.09.2019)	-1.000	1.000	0.687	0.205
	Yangın Sonrası (21.04.2020)	-1.000	1.000	0.674	0.187
	Yangın Sonrası (27.08.2020)	-1.000	1.000	0.646	0.194
	Yangın Sonrası (14.10.2020)	-1.000	1.000	0.613	0.207
	Yangın Sonrası (24.04.2021)	-1.000	1.000	0.674	0.188

**Şekil 6.** NDVI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Normalleştirilmiş Nem Farkı İndeksi (NDMI) değerlerine Tablo 6'da incelendiğinde, yangın öncesi NDMI değerinin 0.3'ten düşük olması, çalışma alanının geniş tutulması ve yerleşim alanlarını da içermesinden kaynaklanmaktadır. Şekil 7'de yangın sonrası değişimler net bir şekilde görülmektedir. Yangın öncesinde ormanlık alanlarda NDMI değeri daha yüksekken, yangın sonrası etkilenen bölgelerde belirgin bir düşüş gözlemlenmiştir. Zamanla bu azalmanın düzelmeye başladığı ve Şekil 7'de belirginleştiği görülmektedir. Koyu mavi renk su ve bitki örtüsünü, açık mavi ve beyaz renkler ise susuz bölgeleri ifade ederek yangının neden olduğu su kaybını görsel olarak ortaya koymaktadır. Bu bulgular, Serra-Burriel vd. (2021) tarafından yapılan çalışmayla uyumlu olup, yangınların bitki örtüsü ve su kaynakları üzerinde önemli etkiler yarattığını ve zamanla bu etkilerin düzelmeye başladığını göstermektedir. Ayrıca yangın sonrası su azalışı ve bitki örtüsündeki gerileme, iyileşme sürecine girdiği gözlemlenmiştir.

Tablo 6. NDMI işlemi değerleri


	Tarih	Min	Maks	Ortalama	StdSap
NDMI	Yangın Öncesi (10.09.2019)	-1.000	1.000	0.212	0.188
	Yangın Sonrası (21.04.2020)	-1.000	1.000	0.174	0.201
	Yangın Sonrası (27.08.2020)	-1.000	1.000	0.166	0.188
	Yangın Sonrası (14.10.2020)	-1.000	1.000	0.161	0.178
	Yangın Sonrası (24.04.2021)	-1.000	1.000	0.273	0.161

**Şekil 7.** NDMI işlem görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Normalleştirilmiş Fark Yerleşim Alanı İndeksi (NDBI) Tablo 7’de yangın sonrası ortalama değerde bir artış gösterdiği gözlemlenmiştir. Bu pozitif artış, yanmış alanlardaki bitki tahribatının başlangıçta negatif değeri göstermesinin ardından, zamanla pozitif değere dönüşmesinden kaynaklanmaktadır. Şekil 8’deki görüntülere bakıldığında, sarıdan mora doğru bir geçiş görülmektedir; ormanlık alanın azalmasıyla birlikte yerleşim alanı bölgesi artmaktadır. Yangından önce sarı renkte olan alanlar bitki varlığını ifade ederken, yangın sonrası bölgede belirgin bir şekilde mor renge dönüşmüştür. Zamanla NDBI değerinin negatif değere düşmesi, tahribatın doğanın kendini yenilemesiyle birlikte bitkilerin yeniden türediğini göstermektedir. Sonuçlar, diğer spektral indekslerle ve çalışmalarla uyumlu bir şekilde çıkmıştır.

Tablo 7. NDBI işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
NDBI	Yangın Öncesi (10.09.2019)	-1.000	1.000	-0.212	0.188
	Yangın Sonrası (21.04.2020)	-1.000	1.000	-0.174	0.201
	Yangın Sonrası (27.08.2020)	-1.000	1.000	-0.166	0.188
	Yangın Sonrası (14.10.2020)	-1.000	1.000	-0.161	0.178
	Yangın Sonrası (24.04.2021)	-1.000	1.000	-0.273	0.161




Şekil 8. NDBI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Gelişmiş Bitki Örtüsü İndeksi (EVI) değerleri, yangın sonrası minimum ve maksimum seviyelerde düşüş göstermiş, bu azalma ortalama değerlere de yansımıştır. Çalışma alanı geniş ve çeşitli arazi örtülerine sahip olsa da yangının etkisi belirgindir. Zamanla ortalama değer artsa da tahribatın hızla düzelmediği görülmektedir. Şekil 9’da kırmızıdan maviye geçiş, bitki örtüsünün toparlanma sürecini yansıtmaktadır. Yangın öncesi mavi tonlar hakimken, yangın sonrası alanlar keskin şekilde kırmızıya dönüşmüştür. Zamanla bu bölgelerde kırmızı tonların azalması ve sarı-maviye dönüşmesi, iyileşme sürecini göstermektedir. Bir yıl sonraki görüntülerde belirgin bir toparlanma olsa da ekosistemin tamamen eski haline dönmesi uzun zaman aldığı anlaşılmaktadır. Fernandes ve Botelho (2003)’e göre de orman yangınından sonra iyileşme süreci zaman alabilmektedir. Ormanın alt tabakasındaki bitki örtüsü ve çalılıkların eski haline gelmesi birkaç yıl sürebilirken, yapraklar ve dallar gibi üst düzey bitki yapılarının iyileşmesi genellikle 2-5 yıl arasında bir süre almaktadır.

Tablo 8. EVI işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
EVI	Yangın Öncesi (10.09.2019)	-0.692	1.000	0.378	0.132
	Yangın Sonrası (21.04.2020)	-0.211	0.935	0.285	0.136
	Yangın Sonrası (27.08.2020)	-0.337	0.984	0.298	0.129
	Yangın Sonrası (14.10.2020)	-1.000	1.000	0.290	0.110
	Yangın Sonrası (24.04.2021)	-0.269	0.842	0.296	0.102

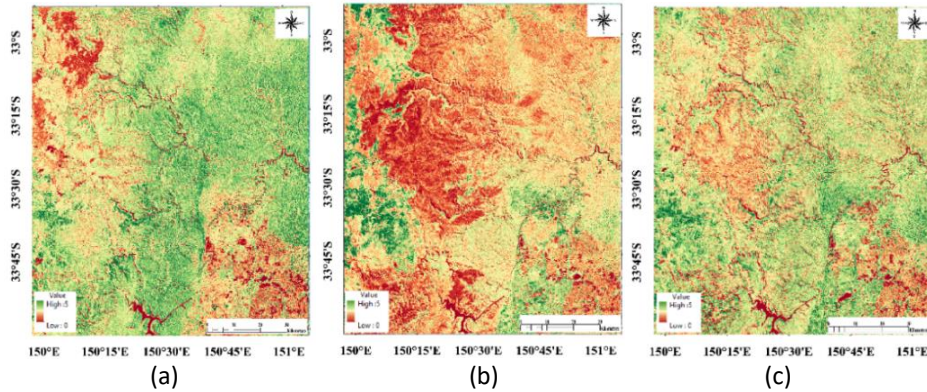


Şekil 9. EVI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Tablo 9'daki Yaprak Alanı İndeksi (LAI) değerleri incelendiğinde, yangın öncesi (10.09.2019) maksimum ve ortalama değerlerin daha yüksek olduğu görülmektedir. Yangın sonrası (21.04.2020) bu değerlerdeki düşüş, yangının ormana verdiği zararı yansıtmaktadır. Ancak, zamanla bu değerler yeniden yükselmiş ve doğanın kendini yenilediği gözlemlenmiştir. Şekil 10'da yangın öncesi ve sonrası LAI değerleri karşılaştırılmıştır. Kırmızı alanlar bitki örtüsünün azaldığını, yeşile doğru geçiş ise yaprak alanının arttığını göstermektedir. Yangın sonrası belirgin bir bitki kaybı yaşanmış, ancak zamanla iyileşme gözlemlenmiştir. Mevsim faktörü bazı renk değişimlerine neden olsa da sonuçlar, Gelişmiş Bitki Örtüsü İndeksi (EVI) ile paralel sonuçlar çıkararak destekler niteliktedir.

Tablo 9. LAI işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
LAI	Yangın Öncesi (10.09.2019)	0.000	4.373	1.2532	0.4200
	Yangın Sonrası (21.04.2020)	0.000	3.236	0.9174	0.4881
	Yangın Sonrası (27.08.2020)	0.000	3.652	0.9652	0.4587
	Yangın Sonrası (14.10.2020)	0.000	3.845	0.9764	0.4532
	Yangın Sonrası (24.04.2021)	0.000	3.972	0.9585	0.3598



Şekil 10. LAI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

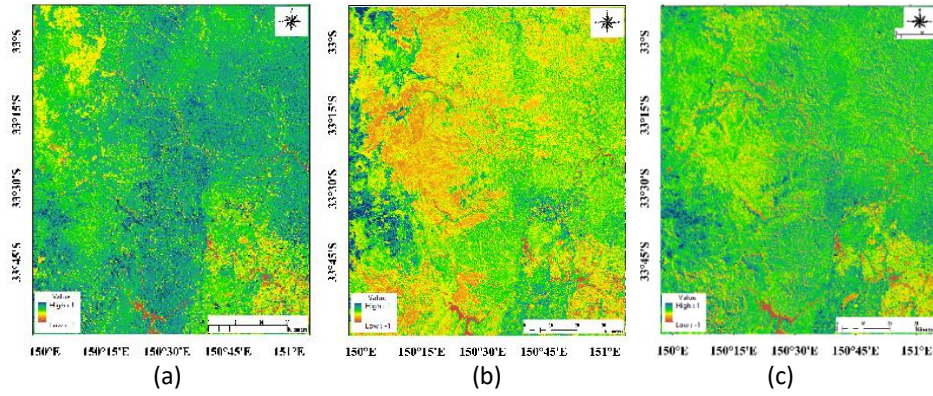
Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI), 1'e yaklaştıkça bitki örtüsünün yoğunluğunu, -1'e yaklaştıkça ise toprak varlığını göstermektedir. Tablo 10'da yangın sonrası minimum ve maksimum değerlerin genel olarak düştüğü, ortalama değerlerdeki azalışın ise toprak örtüsünün açığa çıktığını ve bitki örtüsünün azaldığını gösterdiği görülmektedir. Şekil 11'de, -1 değeri kırmızıdan başlayarak 1'e doğru koyu maviye renklendirilmiştir. Mavi ve yeşil alanlar bitki varlığını, sarı ve kırmızı alanlar ise yanmış bölgelerde toprak yüzeyinin ortaya çıktığını göstermektedir. Yangından hemen sonraki görüntü tahribatı net bir şekilde ortaya koyarken, zamanla çıplak toprak alanlarının azaldığı gözlemlenmiştir.

Sannigrahi vd. (2020), yangın öncesi (2014) ve sonrası (2016) yıllara ait MODIS verileriyle bitki örtüsü ve yanma alanı indekslerinin mekânsal ve zamansal değişimlerini incelemiş ve SAVI'nin orman yangınlarının ekosistem üretkenliği üzerindeki etkilerini değerlendirmede etkili bir araç olduğunu bulmuştur. Benzer şekilde, bu çalışmada da yangın sonrası bitki örtüsündeki değişiklikler ve iyileşme süreci SAVI indeksleriyle izlenmiş, tahribatın sayısal olarak doğrulandığı ve

iyileşmenin zamanla ilerlediği gözlemlenmiştir. Sannıgrahi vd. (2020)'in bulguları doğrultusunda, yangın sonrası çıplak toprak alanlarının azaldığı ve bitki örtüsünün arttığı tespit edilmiştir.

Tablo 10. SAVI işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
SAVI	Yangın Öncesi (10.09.2019)	-0.563	0.898	0.371	0.103
	Yangın Sonrası (21.04.2020)	-0.448	0.910	0.302	0.129
	Yangın Sonrası (27.08.2020)	-0.516	0.885	0.309	0.119
	Yangın Sonrası (14.10.2020)	-0.654	1.000	0.422	0.174
	Yangın Sonrası (24.04.2021)	-0.440	0.761	0.318	0.101



Şekil 11. SAVI işlem görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

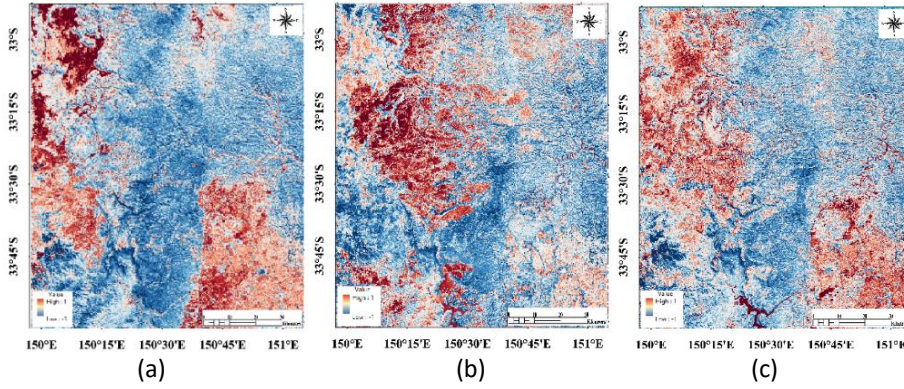
3.3.2 Toprak Örtüsünün Spektral İndeksler ile İncelenmesi

Bu çalışmada toprak örtüsündeki değişimleri multispektral bantlarla birlikte spektral indeksler kullanılarak incelenmiştir. Landsat 8 uydu görüntülerinin toprak üzerinde inceleme için yeterli olup olmayacağı hakkında bilgi vermesi için de bu çalışma yapılmıştır.

Çıplak Toprak İndeksi (BSI) değerlerine Tablo 11'de bakıldığında, ortalama değer arttıkça bitki örtüsünde kayıp olduğu ve çıplak toprak varlığının arttığı anlaşılmaktadır. Görüntüleme uygulanan BSI işlemi sonrasında elde edilen histogram değerleri, bitki varlığının azaldığını ve zamanla doğanın kendini yenilemesiyle orman tahribatının azaldığını göstermektedir. Şekil 12'ye bakıldığında, -1 ile 1 arasında yapılan histogram sınıflandırmasında mavi alanlar bitki örtüsünü, kırmızı alanlar ise çıplak toprağı temsil etmektedir. Orman yangınının etkisiyle çıplak toprak alanlarının arttığı net bir şekilde gözlemlenmiş ve zamanla bu alanların yangın öncesi haline yöneldiği nitel olarak izlenmiştir.

Tablo 11. BSI işlemi değerleri

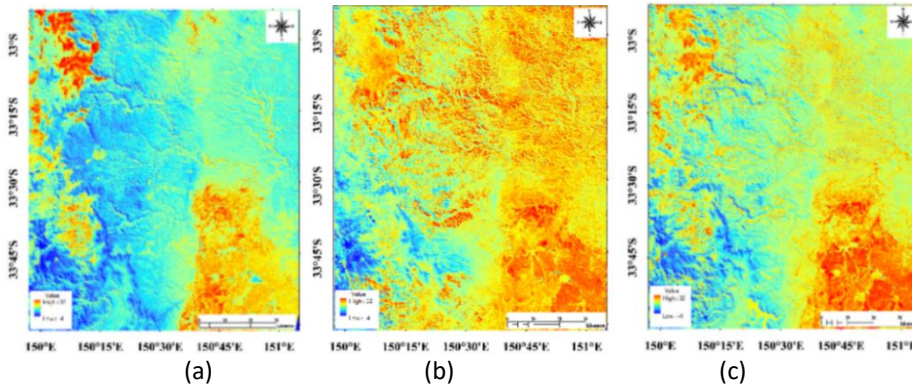
	TARİH	Min	Maks	Ortalama	StdSap
BSI	Yangın Öncesi (10.09.2019)	-1.000	1.000	-0.156	0.178
	Yangın Sonrası (21.04.2020)	-1.000	1.000	-0.099	0.198
	Yangın Sonrası (27.08.2020)	-1.000	1.000	-0.097	0.180
	Yangın Sonrası (14.10.2020)	-1.000	1.000	-0.141	0.157
	Yangın Sonrası (24.04.2021)	-1.000	1.000	-0.190	0.165



Şekil 12. BSI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Arazi Yüzey Sıcaklığı (LST) Tablo 12’de orman yangınından sonraki görüntülerde artış göstermiştir. Bunun sebebi ağaçların güneş ışığını direk yüzeye inmesi engellediği için ve toprakta bulunan yanmış kül tabakası verdiği etkisiyle sıcaklık ortalama değerde olduğu gibi artmıştır. Zamanla yangının vermiş olduğu tahribatın azalması ve doğanın yenilenmesi ile bu değer azalışa geçmiştir. Şekil 13’te, yangın sonrası alanlarda yüksek sıcaklık farkları açıkça görülmektedir. Soğuk alanlar mavi renkle, sıcak alanlar ise sarı ve kırmızı renklerle gösterilmiştir. Zamanla, yangının etkili olduğu bölgelerde sıcaklıkların düşerek soğuma sürecinin başladığı gözlemlenmektedir.

Sannigrahi vd. (2020), MODIS verileri kullanarak yangın öncesi ve sonrası yıllara ait LST hesaplamaları yapmış ve yangın günlerinde LST’nin 6°C ila 9°C arasında arttığını gözlemlemiştir. Bu artış, yangınların ekosistem üzerindeki etkilerini ve yangın riskini değerlendirmede LST’nin önemini vurgulamaktadır. Benzer şekilde, bu çalışmada da yangın sonrası LST değerlerinde gözlemlenen artış, yangının ekosistem üzerindeki tahribatını göstermekte ve zamanla sıcaklık değerlerinin azaldığı, doğanın iyileşme sürecine girdiği ortaya çıkmaktadır.



Şekil 13. LST işlem görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

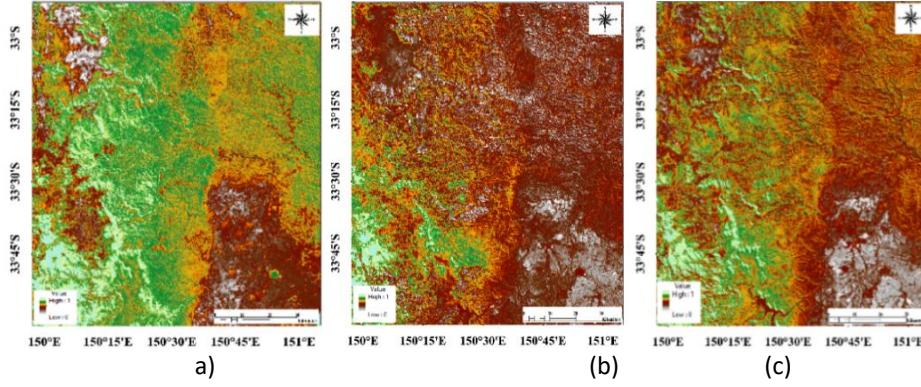
Tablo 12. LST işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
LST	Yangın Öncesi (10.09.2019)	1.584	30.963	15.852	4.376
	Yangın Sonrası (21.04.2020)	-3.211	27.896	18.401	3.452
	Yangın Sonrası (27.08.2020)	1.423	25.851	13.913	4.281
	Yangın Sonrası (24.04.2021)	4.500	24.653	14.707	4.101

Toprak Nem İndeksi (SMI) değeri, LST ile ilişkilidir ve topraktaki nem oranını yansıtmaktadır. 0 ile 1 arasındaki değerler, topraktaki nemin azaldığını ve sonra tekrar arttığını Tablo 13’te göstermektedir. LST değerindeki azalışla birlikte topraktaki nem artmış ve bu da SMI değerinde yükselmeye neden olmuştur. Şekil 14’te, 0 ile 1 arasında yapılan renklendirmede, 1 değeri yeşil renkle fazla nemi, 0 değeri ise kahverengi tonlarıyla kuru toprağı ve düşük nem oranını ifade etmektedir. Yangın öncesi (10.09.2020) nem oranı yüksekken, yangın sonrası (21.04.2020) bu oran düşmüştür. Zamanla, yangının etkilerinin azalması ve sıcaklığın düşmesiyle nem oranında artış gözlemlenmiştir. LST ve SMI arasındaki ilişki, sıcaklık düştükçe toprak neminin arttığını göstermektedir.

Tablo 13. SMI işlemi değerleri


	Tarih	Min	Maks	Ortalama	StdSap
SMI	Yangın Öncesi (10.09.2019)	0.020	1.000	0.114	0.027
	Yangın Sonrası (21.04.2020)	0.009	1.000	0.069	0.022
	Yangın Sonrası (27.08.2020)	0.022	1.000	0.094	0.027
	Yangın Sonrası (24.04.2021)	0.013	1.000	0.070	0.027

**Şekil 14.** SMI değişim görüntüleri a) Yangın öncesi 10.09.2019 b) Yangın sonrası 21.04.2020 c) Yangın sonrası 24.04.2021


Toprak Tuzluluğu İndeksi (SSI) değerleri Tablo 13'te incelendiğinde, yangın öncesi ortalama değerin yangın sonrası düştüğü görülmüştür. Yangının hem bitki örtüsüne hem de toprağa etkisi sayısal olarak yansımıştır. Zamanla bu değerdeki artış, doğanın kendini yenileyebildiğini göstermektedir. Şekil 15'te, yangın öncesinde yüksek olan tuzluluk seviyesinin, yangın sonrası keskin bir renk değişimi ile azaldığı gözlemlenmiştir. Zamanla, yangın alanındaki ekosistem iyileşmeye başlamış ve son görüntülerde bu toparlanma net bir şekilde görülmüştür. Orman yangınları, toprağın kimyasal yapısını bozarak su geçirmez hâle getirdiği için toprağın su tutma kapasitesini ve mineral dengesini etkileyerek tuzluluk seviyelerinde değişikliklere yol açabildiği düşünülmektedir.

Tablo 14. SSI işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
SSI	Yangın Öncesi (10.09.2019)	-1.000	1.000	0.306	0.097
	Yangın Sonrası (21.04.2020)	-1.000	1.000	0.267	0.102
	Yangın Sonrası (27.08.2020)	-1.000	1.000	0.271	0.098
	Yangın Sonrası (14.10.2020)	-1.000	1.000	0.281	0.096
	Yangın Sonrası (24.04.2021)	-1.000	1.000	0.311	0.092

**Şekil 15.** SSI işlemi görüntüleri: a) yangın öncesi 10.09.2019 b) yangın sonrası 21.04.2020 c) yangın sonrası 24.04.2021

Tablo 15 incelendiğinde, yangın sonrası kil mineralinde azalma görülmektedir. Zamanla bu oran pek değişmese de bir yıl sonra eski değerine yaklaşmıştır. Şekil 16'da düşük kil miktarı mavi, yüksek miktarlar ise yeşil ve sonrası renklerle gösterilmiştir. Yangın öncesinde kil miktarı yüksekken, yangın sonrasında belirgin bir düşüş yaşanmıştır. Reynard-Callanan vd. (2010), yangınların topraktaki kil minerallerini azaltarak su tutma kapasitesini olumsuz etkileyebileceğini belirtmiştir. Bu çalışma da benzer sonuçlar göstermiştir. Ayrıca, topraktaki nem artışı SMI değerine yansımış ve bu iki değişken arasındaki ilişkiyi desteklemiştir. Diğer spektral indeksler arasında da bir uyum olması çalışmayı doğrular niteliktedir.



Şekil 16. Kil minerali indeksi işlemi görüntüleri: a) yangın öncesi 10.09.2019, b) yangın sonrası 21.04.2020, c) yangın sonrası 24.04.2021

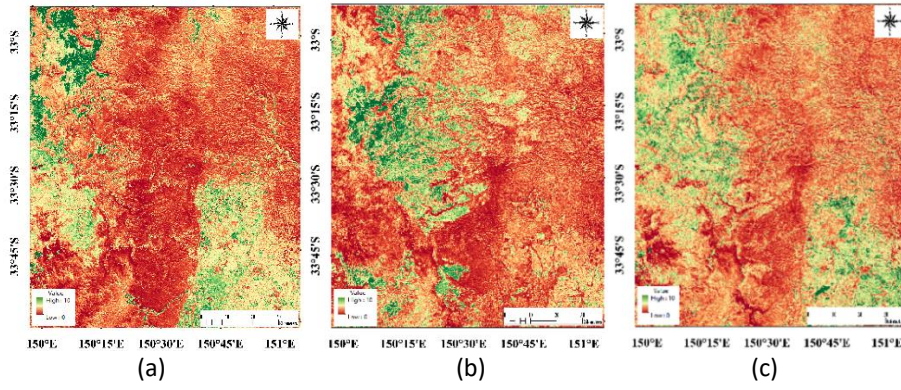
Tablo 15. Kil minerali indeksi işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
Kil Minerali (CM)	Yangın Öncesi (10.09.2019)	0.000	5.000	1.935	0.392
	Yangın Sonrası (21.04.2020)	0.000	5.000	1.782	0.385
	Yangın Sonrası (27.08.2020)	0.000	5.000	1.717	0.367
	Yangın Sonrası (14.10.2020)	0.000	5.000	1.789	0.358
	Yangın Sonrası (24.04.2021)	0.000	5.000	1.951	0.386

Tablo 16 incelendiğinde, maksimum değerler açısından Demir Mineralinin yangın sonrası sistematik bir ilerleyiş göstermediği görülmektedir. Ancak, ortalama değerlere bakıldığında, yangın sonrası belirgin bir artış olup bir yıl sonra azalma yaşanmıştır. Şekil 17'de, kırmızıdan yeşile doğru gidildikçe demir mineralinin arttığı gözlemlenmiştir. Yangın alanında geniş bir yeşil yayılımın oluşması, değerlerin yükseldiğini; zamanla ise bu değerlerin düştüğünü göstermektedir. Sayısal veriler değişimi net olarak yansıtmasa da görüntüler bu durumu desteklemektedir. Demir mineralindeki bu sonuçlar Demir Oksit (Fe_2O_3) Oranı (IOR), Ferröz (Fe^{+2}) ve Ferrik (Fe^{+3}) Oranı ile orantılı şekilde çıkmıştır.

Tablo 16. Demir minerali indeksi işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
Demir Minerali (FM)	Yangın Öncesi (10.09.2019)	0.000	8.411	0.696	0.437
	Yangın Sonrası (21.04.2020)	0.000	8.871	0.763	0.359
	Yangın Sonrası (27.08.2020)	0.000	3.945	0.766	0.333
	Yangın Sonrası (14.10.2020)	0.000	7.253	0.765	0.766
	Yangın Sonrası (24.04.2021)	0.000	4.394	0.598	0.242

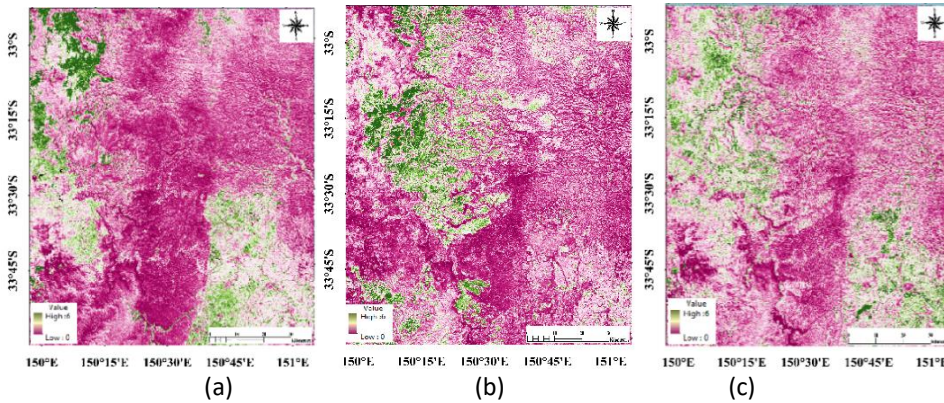


Şekil 17. Demir minerali indeks işlemi görüntüleri: a) yangın öncesi 10.09.2019, b) yangın sonrası 21.04.2020, c) yangın sonrası 24.04.2021

Demir Oksit (Fe_2O_3) Oranı (IOR) değerlerine Tablo 17’de bakıldığında yangın sonrası artış göstermiş, bir yıl sonra ise düşüş yaşanmıştır. Bu durum, demir mineralindeki yükselişle ilişkilidir. Demir minerali ile Demir Oksit arasındaki değerlendirmeler, demir artışının her iki parametreyle doğrulandığını göstermektedir. Şekil 18’de, yanmış alanlarda demir oksit değeri mor renkten yeşil tonlara dönüşerek artışı ortaya koymaktadır. Yangın sonrası bu yükseliş belirgin bir şekilde gözlemlenirken, zamanla değer düşüğe geçerek eski haline dönmeye başlamıştır.

Tablo 17. Demir Oksit İndeks İşlemi Değerleri

	Tarih	Min	Maks	Ortalama	StdSap
Demir Oksit Oranı (IOR)	Yangın Öncesi (10.09.2019)	0.000	5.737	0.696	0.437
	Yangın Sonrası (21.04.2020)	0.000	3.079	0.763	0.359
	Yangın Sonrası (27.08.2020)	0.000	2.724	0.766	0.333
	Yangın Sonrası (14.10.2020)	0.000	4.126	0.765	0.766
	Yangın Sonrası (24.04.2021)	0.000	2.031	0.598	0.242

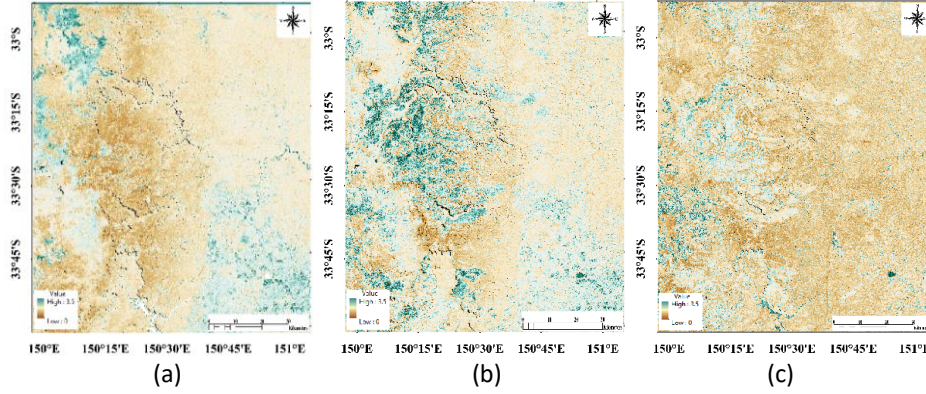


Şekil 18. Demir oksit indeks işlemi görüntüleri: a) yangın öncesi 10.09.2019, b) yangın sonrası 21.04.2020, c) yangın sonrası 24.04.2021

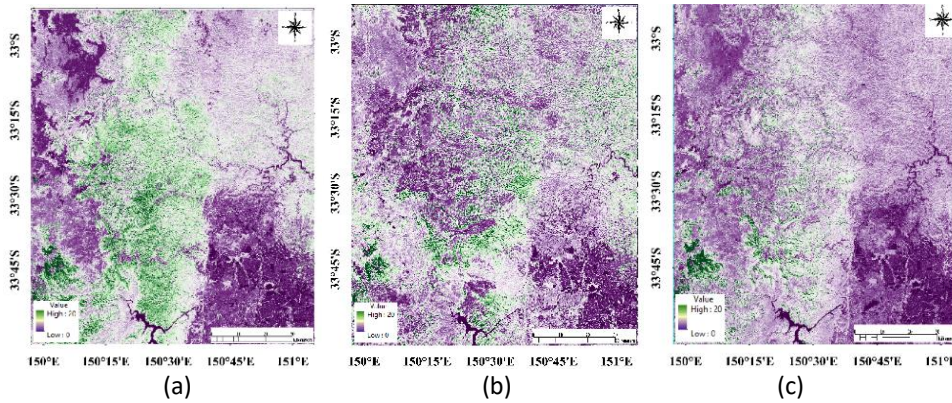
Ferröz (Fe^{2+}) ve Ferrik (Fe^{3+}) oranları Tablo 18 ve Tablo 19’da incelendiğinde, yangın sonrası ortalama değerlerin arttığı, ancak zamanla azaldığı görülmektedir. Bu değişimin, havalanmayan topraklarda gerçekleşen Denklem 1’deki tepkimeyle ilişkili olduğu düşünülmektedir. Bu tepkimede Fe^{3+} miktarında düşüş, Fe^{2+} miktarında ise artış gözlemlenmiştir. Tablo 2’de kullanılan spektral indeksler, bu süreci destekler niteliktedir. Şekil 19’da yangın sonrası Fe^{2+} mineralinde belirgin bir artış gözlemlenmiş, koyu yeşil renk yoğun şekilde baskın hale gelmiştir. Zamanla bu değer düşüş göstermiş ve kahverengi tonlara dönüşmüştür. Fe^{3+} mineralinin istatistik sonuçlarında, yangın sonrası maksimum değerinde azalma gözlenmiş, ancak zamanla tekrar artış meydana gelmiştir. Ortalama değerler ise görüntülerle tam olarak uyumlu bir sonuç vermemiştir. Ancak, Şekil 20 incelendiğinde, yangın öncesinde ormanlık alanlarda yeşil tonların baskın olduğu, yani Fe^{3+} değerinin yüksek olduğu görülmektedir. Yangın sonrasında ise bu değer düşüş göstermiştir.

Tablo 18. Ferröz (Fe^{+2}) indeks işlemi değerleri

	Tarih	Min	Maks	Ortalama	StdSap
Ferröz (Fe^{+2})	Yangın Öncesi (10.09.2019)	0.071	2.704	1.381	0.450
	Yangın Sonrası (21.04.2020)	0.021	2.669	1.448	0.300
	Yangın Sonrası (27.08.2020)	0.069	2.680	1.405	0.288
	Yangın Sonrası (14.10.2020)	0.831	3.226	1.713	0.932
	Yangın Sonrası (24.04.2021)	0.070	2.693	1.259	0.260

**Şekil 19.** Fe^{+2} indeks işlemi görüntüleri: a) yangın öncesi 10.09.2019, b) yangın sonrası 21.04.2020, c) yangın sonrası 24.04.2021**Tablo 19.** Ferrik (Fe^{+3}) indeks işlemi Değerleri

	Tarih	Min	Maks	Ortalama	StdSap
Ferrik (Fe^{+3})	Yangın Öncesi (10.09.2019)	0.000	272.725	6.865	6.161
	Yangın Sonrası (21.04.2020)	0.000	217.236	7.104	7.336
	Yangın Sonrası (27.08.2020)	0.000	230.478	6.794	7.112
	Yangın Sonrası (14.10.2020)	0.000	248.763	4.267	2.010
	Yangın Sonrası (24.04.2021)	0.000	308.456	9.300	15.177

**Şekil 20.** Fe^{+3} indeks işlemi görüntüleri: a) yangın öncesi 10.09.2019, b) yangın sonrası 21.04.2020, c) yangın sonrası 24.04.2021

Yangın sonrası toprak koşulları incelendiğinde, havalanmayan (anaerob) toprak yapısının oluştuğu gözlemlenmiştir. Bu durum, Demir (2009) tarafından belirtilen Denklem 1'e dayanarak değerlendirilmiştir. Landsat 8 uydu görüntüleri kullanılarak yapılan analizlerde, Fe^{2+} ve Fe^{3+} minerallerindeki değişim izlenmiş ve elde edilen sonuçların bu denklemi destekler nitelikte olduğu görülmüştür. Yangın sonrası toprakta anaerob bakterilerin Ferrik (Fe^{3+}) ile etkileşime girerek Ferröz (Fe^{2+}) oluşturduğu, Rowan ve Mars (2003) tarafından sunulan formüllerle de doğrulanmaktadır.

Bu süreç sonucunda toprak pH'ında artış meydana gelmiş ve toprak profili boyunca Fe miktarında belirgin bir yükseliş gözlemlenmiştir. Yapılan analizler, yangın sonrası Fe²⁺ ve Fe³⁺ değişimlerinin bu kimyasal süreçle tutarlı olduğunu ve ekosistem dinamikleri üzerindeki etkilerini ortaya koymaktadır.

Diğer spektral indekslerle bir bütün olarak incelendiğinde, sonuçların birbirleriyle uyumlu olduğu görülmekte ve bu çakışma, yapılan analizlerin doğruluğunu ve güvenilirliğini pekiştirmektedir. Ayrıca, farklı indekslerin birbirini destekleyen sonuçlar üretmesi, inceleme yapılan alanların durumunun daha kapsamlı bir şekilde değerlendirilebilmesini sağlamaktadır. Bu tür bir yaklaşım, literatürde benzer bir çalışmanın bulunmaması nedeniyle, alanındaki özgün ve yenilikçi bir katkı sağlamaktadır.

4. Sonuç ve Öneriler

Orman yangınlarının sayısındaki artış, iklim değişikliğinin etkisiyle birlikte, orman ekosistemleri ve diğer doğal alanlarda yangın ekolojisi açısından ciddi zararlar yaratmaktadır. Bu zararların önüne geçebilmek için özellikle uydu görüntüleri ile arazi ve toprak örtüsündeki değişimin incelenmesi, keşif ekibi ve laboratuvar sonuçları gereksiz bu işlemlerin yapılabilmesi önemli bir gelişme sağlamıştır. Ayrıca yangının orman ekolojisindeki etkisini ve zamanla doğanın kendini yenilemesi hakkında bu çalışma fikir vermiştir. 2019-2020 arasında gerçekleşen orman yangınları Sidney şehrinde ciddi zarara sebebiyet vermiş ve bu zararı Uzaktan Algılama teknolojisi ile son yıllarda uydu teknolojilerinde yaşanan önemli gelişmeler sayesinde incelenmesine aracı olmuştur.

Öncelikle Landsat 8 uydu görüntüsü kullanılarak kontrollü sınıflandırma yöntemi ile hasar tespit çalışmasında 146.981.1 ha (hektar) alanın yandığı hesaplanmış, yangının ciddi boyutta hasara sebebiyet verdiği anlaşılmaktadır. Eşik değer yöntemleri (Otsu, Tsai, Kapur ve Kittler) ile yangında en çok etkilenen multispektral bantların NIR VE SWIR olduğu sonuçlarla değerlendirilmiştir. Yanan Alanı İndeksi (BAI) ile yanan alanlardaki bir senelik süreçte hızlı bir düzelme olduğu saptanmıştır. Arazi bitki örtüsündeki değişim için NDVI, EVI, LAI, NDMI, NDBI ve SAVI indekslerine bakılmıştır. Yangın öncesi ve sonrası büyük bir değişim olduğu hem nicel hem de nitel olarak sonuçlar sunulmuştur. Toprak örtüsündeki değişim için BSI, LST, SMI, SSI indekslerine bakılmıştır. Yangından sonra çıplak toprak görüntüsünün ortaya çıktığı bu sebeple arazi yüzey sıcaklığının arttığı ve buna bağlı olarak nem oranının da düştüğü belirlenmiştir. Bu düşüş topraktaki tuzluluğun azalmasına da sebebiyet vermiştir. Toprak içerisinde bulunan mineraller için Kil, Demir, Demir Oksit, Ferröz (Fe²⁺) ve Ferrik (Fe³⁺) değerlerine bakılmıştır. Sonuçlarda kil ve ferrik miktarında azalma olduğu ve demir, demir oksit ve ferröz da artış olduğu gözlenmiştir. Demirdeki artışın Denklem 1'de ki tepkimenin sonucundan dolayı olduğu ve diğer mineral ve oranların sonucuna bakılarak da anlaşılmaktadır. Bu döngünün oluşmasında, yangından sonraki süreçte kül tabakasının havalanmayan toprak meydana getirdiği ve bu sebeple Fe³⁺ ile anaerobik canlılarının etkileşime girerek ferrikte azalışa ve çıkan tepkimededen ferröz oluşmasıyla demirde artışa neden olmuştur. Böylece bitkilerin yeniden canlanmasında, büyümesinde ve fotosentez yapmasında önemli olan demirin yangından sonraki süreçte açığa çıkması ormanların yeniden kazanılmasında bilgi vermiştir.

Çalışmadan elde edilen sonuçlar, yangının ciddi zarar verdiğini, bitki örtüsünün kaybolmasıyla çıplak toprağın açığa çıktığını ve yüzey sıcaklığının arttığını göstermektedir. Bunun sonucunda, toprak neminde ve tuzluluğunda azalma meydana gelmiş, ancak yangın sonrası demir seviyesindeki artış, bitkilerin yeniden canlanması açısından önemli bir etken olarak belirlenmiştir. Bu çalışma, yangının bitkiler ve toprak üzerinde olumsuz etkiler bıraktığını, bir yıl sonra iyileşme sürecinin başladığını ancak eski haline dönmesi için daha uzun bir süre gerektiğini, diğer çalışmalarda belirtilen bulgularla tutarlı şekilde ortaya koymuştur. Yangının topraktaki birçok etkisini inceleyebilmek için Multispektral bantlar yerine hiperspektral bantların kullanılması daha fazla analiz yapılabilmesi ve daha sağlıklı sonuç vereceği de düşünülmektedir.

Uzaktan Algılamanın orman yangınları üzerinde kullanılması, bilgi edilebilirliği açısından önemli olduğu ve hem zaman hem de maddi anlamda kolaylık sağlayabileceği bu çalışma sonucunda elde edilmiştir. Ayrıca ekosistemin kaybettiği arazi örtüsünün ne kadar sürede geri kazandığını belirlemek, değişimleri analiz etmek ve yangın sonrasında bu sürecin nasıl değerlendirilmesiyle gerektiğine katkı sağlamaktadır. Uzaktan algılama ile orman yangınlarında hasar alan bölgelerin keşfi ve tekrar doğaya kazandırılması, yangından sonra toprak örtüsünün nasıl değiştiği, yangını engellemek için yangına dayanıklı bitkilerin ekilmesinde karar vericilere yardımcı olacaktır.

Kaynaklar

- Anadolu Ajansı. (2023). *Dünyada son 10 yılda yaklaşık 82 milyon hektar ormanlık alan yandı*. <https://www.aa.com.tr/tr/dunya/dunyada-son-10-yilda-yaklasik-82-milyon-hektar-ormanlik-alan-yandi/2954614>
- Alganci, U., Sertel, E., & Örmeci, C. (2010, May 31–June 4). *Forest fire damage estimation using remote sensing and GIS* [Symposium presentation]. 30th EARSeL Symposium - Remote Sensing for Science, Education, and Natural and Cultural Heritage, Paris, France.
- Al-Khaier, F. (2003). *Soil salinity detection using satellite remote sensing* [Master's thesis, University of Twente]. ITC Publications. <https://essay.utwente.nl/104064/>

- Aslan, E., Yılmaz, K., & Demir, Ö. F. (2016). Bitlis yöresi topraklarının kil minerali ve toprak özellikleri ilişkileri. *Çukurova Tarım Gıda Bilişimi Dergisi*, 31(3), 201–206.
- Aydın, M., Uğış, A., Akkuzu, E., & Ünal, S. (2017). Orman yangınlarının su kaynakları üzerindeki etkileri. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, 17(4), 554–564. <https://doi.org/10.17475/kastorman.369008>
- Bilgili, E. (2014). *Orman yangınlarının orman ekosistemleri üzerindeki etkileri*. 25 Nisan 2021'de https://www.ktu.edu.tr/dosyalar/ormankoruma_213b0.pdf adresinden alındı.
- Boegh, E., Soegaard, H., Broge, N., Hasager, C., Jensen, N., Schelde, K., & Thomsen, A. (2002). Airborne multi-spectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote Sensing of Environment*, 81(2–3), 179–193.
- Canlı, K. (2010). Küresel ısınmanın orman ekosistemine etkisi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(2), 86–96.
- Certini, G. (2005). Effects of fire on properties of forest soils: A review. *International Journal of Wildland Fire*, 14(3), 429–442. <https://doi.org/10.1007/s00442-004-1788-8>
- Chandler, C. C., Cheney, P., Thomas, P., Trabaud, L., & Williams, D. (1983). *Fire in forestry. Volume 1: Forest fire behavior and effects*. John Wiley & Sons.
- Chen, W., Liu, L., Zhang, C., Wang, J., & Pan, Y. (2004, September 20–24). *Monitoring the seasonal bare soil areas in Beijing using multitemporal TM images* [Symposium presentation]. 2004 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Anchorage, AK, USA.
- Chuvieco, E., Martin, M. P., & Palacios, A. (2002). Assessment of different spectral indices in the red-near-infrared spectral domain for burned land discrimination. *International Journal of Remote Sensing*, 23(23), 5103–5110.
- Çepel, N. (1975). Orman yangınlarının mikroklima ve toprak özellikleri üzerine yaptığı etkiler. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 25(1), 71–93.
- Çelik, M. Ö., Fidan, D., Ulvi, A., & Yakar, M. (2023). Akdeniz Bölgesi'ndeki orman yangınlarının uzaktan algılama ve coğrafi bilgi sistemleri kullanılarak değerlendirilmesi: Mersin ili Silifke ilçesi örneği. *Anadolu Orman Araştırmaları Dergisi*, 9(2), 116–125.
- Demir, T. (2009). *Ankara Üniversitesi açık ders notları malzemeleri: Demir minerali*. 12 Nisan 2021'de https://acikders.ankara.edu.tr/pluginfile.php/205632/mod_resource/content/0/11.HAFTA.pdf adresinden alındı.
- Demirci, R., Güvenç, U., & Kahraman, H. T. (2014). Görüntülerin renk uzayı yardımıyla ayrıştırılması. *İleri Teknoloji Bilimleri Dergisi*, 3(1), 1–8.
- Demir, Z., & Kıdıl, F. (2020). *Orman yangın alanlarının uzaktan algılama yöntemleriyle tespiti* [Bitirme çalışması, Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği]. Trabzon.
- De Santis, A., & Chuvieco, E. (2007). Burn severity estimation from remotely sensed data: Performance of simulation versus empirical models. *Remote Sensing of Environment*, 108, 422–435. <https://doi.org/10.1071/WF05097>
- Dogan, H. (2009). Mineral composite assessment of Kelkit River Basin in Turkey by means of remote sensing. *Journal of Earth System Science*, 118, 701–710.
- EOS Data Analytics Inc. (2020). *NDMI (Normalleştirilmiş Fark Nem İndeksi)*. 11 Mayıs 2021'de <https://eos.com/make-an-analysis/ndmi/> adresinden alındı.
- Fernandes, P. M., & Botelho, H. S. (2003). Fire behavior and severity in Mediterranean-type ecosystems: Implications for fire management. *Fire Ecology Journal*, 25(2), 55–65.
- Firo. (2012, 26 Ocak). *Topraktaki Demir Mineralleri*. 21 Mart 2021'de <https://www.firochromis.com/?p=944> adresinden alındı.
- Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266.
- Ghazali, M. F., Wikantika, K., & Harto, A. B. (2019). Generating soil salinity, soil moisture, soil pH from satellite imagery and its analysis. *Information Processing in Agriculture*, 7(2), 264–306. <https://doi.org/10.1016/j.inpa.2019.08.003>
- Gibbons, P., Lindenmayer, D. B., & Soderquist, T. (2020). Ecological impacts of fire in Australian forests: A review. *Forest Ecology and Management*, 307, 23–37.
- Hatfield, J. L., Kanemasu, E. T., Asrar, G., Jackson, R. D., Pinter, P. J. Jr., Reginato, R. J., & Idso, S. B. (1985). Leaf area estimates from spectral measurements over various planting dates of wheat. *International Journal of Remote Sensing*, 6, 167–175.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309.
- Huete, A. R., Liu, H., Batchily, K., & van Leeuwen, W. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59(3), 440–451.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83, 195–213.
- Hunt, G. (1977). Spectral signatures of particulate minerals in the visible and near infrared. *Geophysics*, 42(2), 401–413.

- Kapur, J. N., Sahoo, P. K., & Wong, A. K. C. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. *Graphical Models and Image Processing*, 29, 273–285.
- Kayman, Ö. (2015). *Spektral indekslerin arazi örtüsü/kullanımı sınıflandırmasına etkisi: İstanbul, Beylikdüzü ilçesi arazi kullanımı değişimi* [Yüksek lisans tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Key, C. H., & Benson, N. C. (2006). Landscape assessment (LA): Sampling and analysis methods. In D. C. Lutes, R. E. Keane, J. F. Caratti, C. H. Key, N. C. Benson, S. Sutherland, & L. J. Gangi (Eds.), *Firemon: Fire Effects Monitoring and Inventory System* (pp. LA1–LA51). USDA Forest Service, Rocky Mountain Research Station.
- Khaneghah, A. R. N. (2016). *Estimating land surface temperature (LST) using ENVI5.3: Landsat8*. <https://www.youtube.com/watch?v=GG2b74vkEfl>
- Kılıçaslan, M., Tanyeri, U., & Demirci, R. (2018). Renkli görüntüleri için tek boyutlu histogram. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6, 1094–1107.
- Kittler, J., & Illingworth, J. (1986). Minimum error thresholding. *Pattern Recognition*, 19, 41–47.
- Lopez Garcia, M., & Caselles, V. (1991). Mapping burns and natural reforestation using thematic mapper data. *Geocarto International*, 6, 31–37.
- Neary, D. G., Klopatek, C. C., DeBano, L. F., & Ffolliott, P. F. (1999). Fire effects on belowground sustainability: A review and synthesis. *Forest Ecology and Management*, 122, 51–71.
- NİK Sistem. (2020). *Landsat-8 teknik özellikler*. https://www.nik.com.tr/content_sistem_uydu.asp?id=49
- Otsu, N. (1979). A threshold selection method from gray level histogram. *IEEE Transactions on System, Man and Cybernetics*, SMC-9(1), 62–66.
- Partheepan, S., Sanati, F., & Hassan, J. (2024). *Bushfire severity modelling and future trend prediction across Australia: Integrating remote sensing and machine learning*. arXiv. <https://doi.org/10.48550/arXiv.2410.02963>
- Pashaei, H. M., & Aksoy, T. (2022). Arazi örtüsünün mekânsal ve zamansal olarak değişiminin yer yüzey sıcaklığına olan etkisinin uzaktan algılama yöntemi ile belirlenmesi, İstanbul Pendik ilçesi örnekleme. *GSI Journals Serie C: Advancements in Information Sciences and Technologies (AIST)*, 5(2), 1–22.
- Reynard-Callanan, J., Pope, G., Gorring, M., & Feng, H. (2010). Effects of high-intensity forest fires on soil clay mineralogy. *Physical Geography*, 31(5), 407–422. <https://doi.org/10.2747/0272-3646.31.5.407>
- Robichaud, P. R. (2000). Fire effects on soil properties and processes. *Fire Ecology Journal*, 5(1), 23–36.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973, December 10–14). *Monitoring vegetation systems in the Great Plains with ERTS (Earth Resources Technology Satellite)* [Symposium presentation]. 3rd Earth Resources Technology Satellite Symposium, Washington, D.C.
- Rowan, L. C., & Mars, J. C. (2003). Lithologic mapping in the Mountain Pass, California area using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) data. *Remote Sensing of Environment*, 84, 350–366.
- Rulli, M. C., & Rosso, R. (2007). Soil erosion and water retention following forest fires in Mediterranean ecosystems. *Environmental Management*, 40(2), 189–203.
- Sabuncu, A., & Özener, H. (2019). Uzaktan algılama teknikleri ile yanmış alanların tespiti: İzmir Seferihisar orman yangını örneği. *Doğal Afetler ve Çevre Dergisi*, 5(2), 317–326. <https://doi.org/10.21324/dacd.511688>
- Sannigrahi, S., Pilla, F., Basu, B., Basu, A. S., Sarkar, K., Chakraborti, S., Joshi, P. K., Zhang, Q., Wang, Y., Bhatt, S., Bhatt, A., Jha, S., Keesstra, S., & Roy, P. S. (2020). Examining the effects of forest fire on terrestrial carbon emission and ecosystem production in India using remote sensing approaches. *Science of The Total Environment*, 725, Article 138331. <https://doi.org/10.1016/j.scitotenv.2020.138331>
- Segal, D. (1982, December 6). *Theoretical basis for differentiation of ferric-iron bearing minerals using Landsat MSS data* [Conference presentation]. International Symposium for Remote Sensing of Environment, 2nd Thematic Conference on Remote Sensing for Exploratory Geology, Fort Worth, TX, USA.
- Serra-Burriel, F., Delicado, P., Prata, A. T., & Cucchiatti, F. M. (2021). Estimating heterogeneous wildfire effects using synthetic controls and satellite remote sensing. *Remote Sensing of Environment*, 265, Article 112649. <https://doi.org/10.1016/j.rse.2021.112649>
- Sezgin, M. (2002). *İmge eşikleme yöntemlerinin başarımlarını değerlendirme ve tahribatsız muayenede kullanımı* [Doktora tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Singh, S., Singh, H., Sharma, V., Shrivastava, V., Kumar, P., Kanga, S., Sahu, N., Meraj, G., Farooq, M., & Singh, S. K. (2021). Impact of forest fires on air quality in Wolgan Valley, New South Wales, Australia—A mapping and monitoring study using Google Earth Engine. *Forests*, 13(1), Article 4. <https://doi.org/10.3390/f13010004>
- Tsai, W. H. (1985). Moment-preserving thresholding: A new approach. *Graphical Models and Image Processing*, 19, 377–393.
- Tonbul, H. (2015). *Uydu görüntü verileri kullanılarak orman yangını şiddeti ve yangın sonrası son durumun zamansal olarak incelenmesi: Akdeniz örneği* [Yüksek lisans tezi, İstanbul Teknik Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>

- Wang, J., & Qu, J. J. (2007). A method for estimating soil moisture with thermal infrared remote sensing. *Remote Sensing of Environment*, 108(4), 477–484. <https://doi.org/10.1016/j.rse.2007.01.008>
- Weng, Q., Lu, D., & Schubring, J. (2004). Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. *Remote Sensing of Environment*, 89(4), 467–483.
- Xu, H., Chen, J., He, G., Lin, Z., Bai, Y., Ren, M., Zhang, H., Yin, H., & Liu, F. (2024). Immediate assessment of forest fire using a novel vegetation index and machine learning based on multi-platform, high temporal resolution remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 134, Article 104210. <https://doi.org/10.1016/j.jag.2024.104210>
- Yıldız, D., & Özgler, H. (2021). Kuraklık, orman yangınları ve ekosistem dengesi. 30 Mart 2021’de <https://www.hidropolitikakademi.org/uploads/editor/images/Kurakl%C4%B1k%20Orman%20Yang%C4%B1nlar%C4%B1%20ve%20Ekosistem%20Dengesi%20.pdf> adresinden alındı.
- Yıldız, H., Mermer, A., Ünal, E., & Akbaş, F. (2012). Trkiye bitki rtsnn NDVI verileri ile zamansal ve mekansal analizi. *Tarla Bitkileri Merkez Arařtırma Enstits Dergisi*, 21(2), 50–56.
- Yılmaz, B., Demirel, M., & Bektaş Balçık, F. (2022). Yanmış alanların Sentinel-2 MSI ve Landsat-8 OLI ile tespiti ve analizi: Çanakkale/Gelibolu orman yangını. *Dođal Afetler ve Çevre Dergisi*, 8(1), 76–86.
- Yılmaz, K. (1984). *Adana, Seyhan, Berdan ve Gks ovalarında yaygın olarak bulunan bazı toprak serilerindeki kil minerallerinin X-ışınları difraksiyonu yntemi ile kantitatif analizi* [Yksek lisans tezi, Çukurova niversitesi]. YK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Yksel, K. (2022). Evaluation of different remote sensing indices in detection of forest burned area: A case study of 2022 Mersin (Glnar) wildfire. *ArtGrid—Journal of Architecture Engineering and Fine Arts*, 4(2), 160–171.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>

Vision Foundation Models and Rule-Based Approaches for Roof Surface Segmentation and Photovoltaic Potential Analysis in Urban Areas

Kentsel Alanlarda Çatı Yüzey Segmentasyonu ve Fotovoltaik Potansiyel Analizinde Görsel Temel Model ve Kural Tabanlı Yaklaşımlar

Samed Özdemir^{1*}, Ahmet Yavuzdoğan¹

¹Gümüşhane University, Faculty of Engineering and Natural Sciences, Geomatics Engineering, Gümüşhane/Türkiye.

ORIGINAL PAPER

*Corresponding author:

Samed Özdemir
samed.ozdemir@gumushane.edu.tr

doi: 10.48123/rsgis.1606873

Article history

Received: 24.12.2024
Accepted: 06.03.2025
Published: 26.03.2025

Abstract

This study presents two methods for rapidly and effectively determining the photovoltaic (PV) potential of building roofs in urban areas using aerial photographs and point cloud data. In the first method, the Segment Anything Model (SAM) and Contrastive Language Image Pre-Training (CLIP) models are used to detect roof surfaces and obstacles from aerial photographs. In the second method, the Random Sample Consensus (RANSAC) and Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algorithms are employed to identify roof surfaces from Light Detection and Ranging (LiDAR) point clouds. Through the first proposed method, the performance of current deep learning approaches in 2.5D PV potential analysis is investigated, while the second approach examines the performance of 3D PV potential analysis compared to the 2D approach. In PV potential analysis, the Photovoltaic Geographical Information System (PVGIS) Application Programming Interface (API) was utilized. The analysis is conducted based on roof parameters obtained through both proposed methods. In building detection, the first approach achieved an Intersection over Union (IoU) score of 94.29%, whereas the second approach attained an IoU score of 91.23%.

Keywords: Deep learning, Photovoltaic potential, Point cloud, Roof segments, Semantic segmentation

Özet

Bu çalışma, kentsel alanlarda bina çatılarının fotovoltaik (FV) potansiyelinin hava fotoğrafları ve nokta bulutu verileri üzerinden hızlı ve etkin bir şekilde belirlenmesi için iki yöntem sunulmaktadır. İlk yöntemde, hava fotoğraflarından çatı yüzeyleri ve engellerin tespiti için Segment Anything Model (SAM) ve Contrastive Language Image Pre-Training (CLIP) modelleri kullanılmaktadır. İkinci yöntemde ise Light Detection and Ranging (LiDAR) nokta bulutlarından çatı yüzeylerinin tespitinde Random Sample Consensus (RANSAC) ve Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algoritmaları kullanılmaktadır. Çalışmada önerilen ilk yöntem sayesinde güncel derin öğrenme yaklaşımlarının 2.5B FV potansiyel analizindeki başarımı araştırılırken, önerilen ikinci yaklaşım ile 3B FV potansiyel analizinin 2B yaklaşıma göre başarımı ele alınmaktadır. FV potansiyel analizinde, PhotoVoltaic Geographical Information System (PVGIS) Application Programming Interface (API)'si kullanılmıştır. Önerilen her iki yöntemle elde edilen çatı parametreleri üzerinden analiz edilmektedir. Bina tespitinde, ilk yaklaşım %94.29 IoU skoru elde ederken ikinci yaklaşım ile elde edilen IoU skoru %91.23 olmuştur.

Anahtar kelimeler: Çatı yüzeyi, Derin öğrenme, Fotovoltaik potansiyel, Nokta bulutu, Semantik segmentasyon

1. Introduction

Cities, now home to over 55% of the global population, are central to addressing the challenges posed by energy consumption and carbon dioxide (CO₂) emissions, which they contribute to at an alarming rate—approximately two-thirds of the global total. The rapid increase in these emissions is largely driven by population growth, urbanization, and increased economic activities within these densely populated areas (Ranald et al., 2021). In response to these challenges, numerous cities and local governments have set ambitious goals to develop net zero-carbon emission buildings, aiming for greater energy self-sufficiency (Li & Han, 2022). The increasing feasibility of photovoltaic (PV) systems is supported by the widespread availability of unused urban rooftops, combined with declining costs and simplified installation processes, making solar energy a key solution to urban energy demands (Minelli et al., 2023, Huang et al., 2022). Due to the significant potential of rooftop solar PV systems, accurately estimating the total installed solar PV capacity and power generation is essential for guiding policymakers and stakeholders (Mao et al., 2023).

Satellite and aerial imagery play a crucial role in various geospatial applications, including the identification of land cover types (Kavzoglu et al., 2024; Sahak et al., 2023; Topaloğlu et al., 2022; Yagmur et al., 2022), road mapping (Ozturk et al., 2022) and building extraction (Comert & Kaplan, 2018; Tonbul & Kavzoglu, 2020). The introduction of LiDAR technology opened new frontiers in the remote sensing community, enabling more precise and efficient road mapping (Ma et al., 2022; Ozturk et al., 2023; Zhao et al., 2019), forestry (Özdemir et al., 2021), land cover (Akumu & Dennis, 2023; Hansch & Hellwich, 2021) mapping applications. In recent years, the growing demand for PV energy production has made PV potential analysis a critical area of research where advancements in the remote sensing technology made it a very viable tool for renewable energy applications (Huang et al., 2022; Lan et al., 2021; Stack & Narine, 2022; Zhong et al., 2021). PV potential studies can be broadly classified into 2D, 2.5D, and 3D based on the data type used (Özdemir et al., 2023). 2D approaches utilize remotely sensed imagery acquired from aerial or satellite platforms to detect and segment roof surfaces using image processing or machine learning techniques. This approach assumes all building roofs as flat and uninterrupted surfaces, which leads to an overestimation of PV potential and makes it unsuitable for accurate applications. In contrast, 2.5D approaches aim to mitigate the inaccuracies of 2D methods by employing Digital Surface Models (DSMs) derived from point clouds or 3D city models. Similar to 2D approaches, building roofs are extracted using image processing or machine learning techniques. The extracted roof boundaries are then matched with the DSM to acquire tilt and azimuth values, which are subsequently used for PV potential estimation. While 2.5D techniques offer a more accurate PV potential estimation compared to 2D approaches, converting 3D data to 2.5D results in information loss, along with increased processing time. 3D approaches, on the other hand, employ 3D city models or point clouds directly without any data conversion, resulting in more accurate and effective PV potential estimates. However, acquiring and processing LiDAR data is a complex task due to the irregular nature of point clouds, and not all city-scale 3D models are readily available.

This study presents two approaches for analyzing rooftop PV potential, one utilizing 2.5D deep learning techniques and the other employing 3D point clouds. The proposed methods were tested on the ISPRS Vaihingen dataset. In the first approach, zero-shot segmentation of the aerial imagery of the study area was carried out with Segment Anything Model (SAM), which is a state of the art Visual Foundation Model (VFM). Subsequently, the Contrastive Language-Image Pre-Training (CLIP) model was employed to zero-shot labelling of the extracted image segments. SAM was then re-applied to each building segment to detect rooftop surfaces and any obstacles on them. The second approach involved using LiDAR point clouds of the study area, where roof surfaces were identified through the RANSAC and DBSCAN algorithms employing an open source QGIS plugin called Solar Potential Analyzer (SPAN) developed by (Özdemir et al., 2023). In determining roof surface parameters, the first method calculates slope, aspect, and area of individual rooftops using the DSM, while the second method directly derives these parameters from the point cloud data. For the PV potential analysis of roof surfaces, the PVGIS database (https://re.jrc.ec.europa.eu/pvg_tools/en/) was utilized. Queries generated based on the calculated rooftop parameters and geographic locations were sent through an API to the PVGIS database to retrieve the daily, monthly, and annual PV production data for each rooftop surface. In the roof segmentation stage, the first approach using on SAM and CLIP achieved an IoU score of 97.94% on the first study area and 94.29% IoU score in the second study area. For the second approach, IoU scores of 76.04% were achieved on the first study area, followed by scores of 91.23% on the second study area. Both approaches yielded successful results in PV potential analysis and demonstrated scalability, making them suitable for applications ranging from individual buildings to city-wide scales.

2. Material and methods

This section provides a detailed description of the methods and datasets used in the segmentation of rooftop surfaces and the analysis of PV potential from aerial imagery and point clouds. Initially, the study areas and datasets employed

for PV potential analysis are introduced. Following this, the algorithms and deep learning models utilized for rooftop surface segmentation from aerial imagery and point clouds are presented, along with a step-by-step explanation of the segmentation process. The accuracy metrics used for evaluating the segmentation results are also introduced. Finally, the methodology employed for conducting the PV potential analysis of the identified rooftop surfaces is described.

2.1. Dataset and Study Area

The ISPRS Vaihingen dataset was collected during flights conducted in 2008 in the Vaihingen region of Germany by the German Association of Photogrammetry and Remote Sensing (DGPF) to test digital aerial cameras (Cramer, 2010). The dataset consists of BGNIR (Blue, Green, and Near-Infrared) orthophotos with a spatial resolution of 8 cm, a LiDAR point cloud with a density of approximately 6.7 points/m², and a DSM with a spatial resolution of 25 cm derived from the point cloud. For this study, two sub-areas from the Vaihingen dataset, referred to as Area 1 and Area 2, were selected (Figure 1). Area 1, measuring 76 × 70 meters, contains six buildings with similar roof types but varying sizes and few rooftop details. In contrast, Area 2, measuring 86 × 64 meters, contains four buildings with more complex rooftop surfaces and numerous rooftop details compared to Area 1.

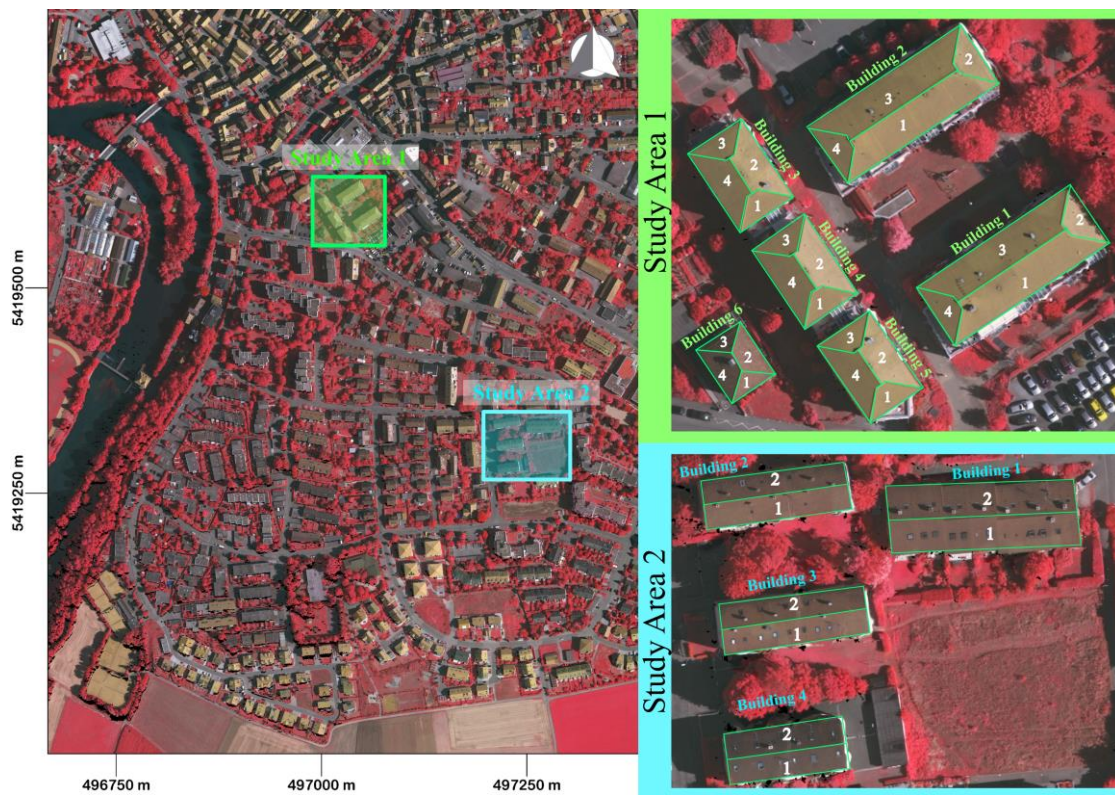


Figure 1. Selected study areas from the ISPRS Vaihingen dataset

2.2. Roof Surface Segmentation Pipeline

Two distinct methods have been proposed for the detection of roof surfaces. The first method involves using Vision Foundation Models (VFM) on aerial photographs to identify roof surfaces, employing the Segment Anything model and CLIP VFM during this phase. The second method detects roof surfaces from aerial LiDAR point clouds using rule-based approaches with RANSAC and DBSCAN algorithms. The PV potential of the identified roof surfaces has been calculated using the PVGIS database. The proposed methods are detailed in the following sections with a comprehensive analysis of each approach's methodology and outcomes.

2.2.1. Roof Surface Segmentation from Aerial Imagery

Orthophoto images have been segmented individually for each roof surface using the "Segment Anything Model" and "Contrastive Language-Image Pre-Training (CLIP)" models. The "Segment Anything Model" has been developed by META AI as a foundational model for image segmentation, trained on the SA-1B dataset (Kirillov et al., 2023).

The SAM model, incorporating a Vision Transformer (ViT), is capable of generating segmentation masks for any type of object within an image. The operation of the SAM model for image segmentation involves either placing points on the object to be segmented or drawing a bounding box around it. Additionally, for fully automated segmentation, the model can also perform this process by placing points on the image at predetermined intervals. Fundamentally, the SAM model comprises three main components: an Image Encoder, a Prompt Encoder, and a Mask Decoder (Figure 2).

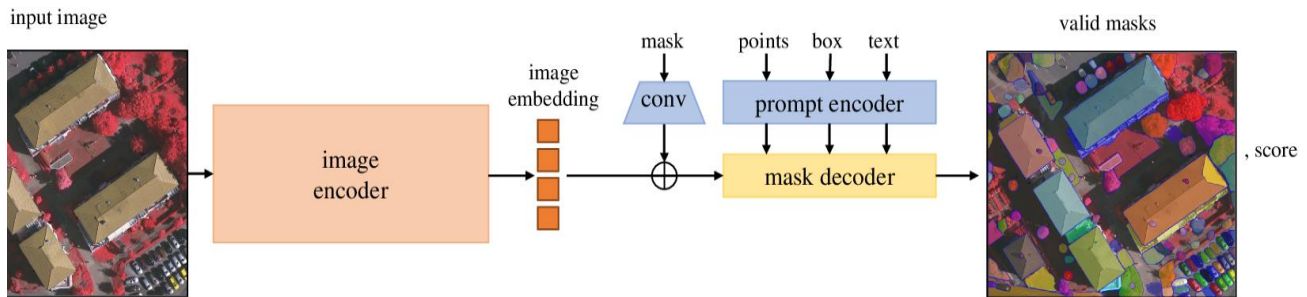


Figure 2. Segment anything model architecture (Kirillov et al., 2023)

CLIP (Contrastive Language–Image Pretraining), developed by OpenAI, is a deep learning model capable of learning relationships between language and image data (Radford et al., 2021). The CLIP model is designed to establish meaningful connections between text and images and to apply this knowledge across broad applications. One of the key features of the CLIP model is zero-shot learning, allowing it to adapt to new tasks that it has not encountered during training. The CLIP model can perform image-text matching using instructions given in natural language. The architecture of CLIP utilizes two separate networks to process language and image data: a Vision Transformer (ViT) model and a language model (a Transformer-based text encoder) (Figure 3). CLIP enhances the learning of semantic congruence between images and associated text by bringing the image and its related text closer together. The training of the CLIP model employs a contrastive loss function that aims to maximize the difference between positive and negative examples. A positive example represents a match between an image and a correctly describing text, while a negative example denotes a match between an image and a randomly selected misleading text.




Figure 3. CLIP model architecture (Radford et al., 2021)

The aerial photographs of the study area were conditioned to segment all objects within the photographs using the SAM model. Subsequently, all the generated segments were classified into two categories—building and non-building—based on the query “Is this a building?” sent to the CLIP model. Segments labeled as buildings were further segmented from the aerial photographs and then re-submitted to the SAM model to ensure segmentation of all objects again. Segments smaller than 100×100 pixels were discarded, leaving only roof surfaces. After the segmentation process of buildings and roof surfaces from the images was completed, azimuth, slope (through DSM), and area information for each roof surface were calculated. Using the Global Horizontal Irradiance (GHI) data obtained via the PVGIS API, a PV potential estimate was performed with a module developed in a Python environment. The workflow of the applied approach is depicted in Figure 4.

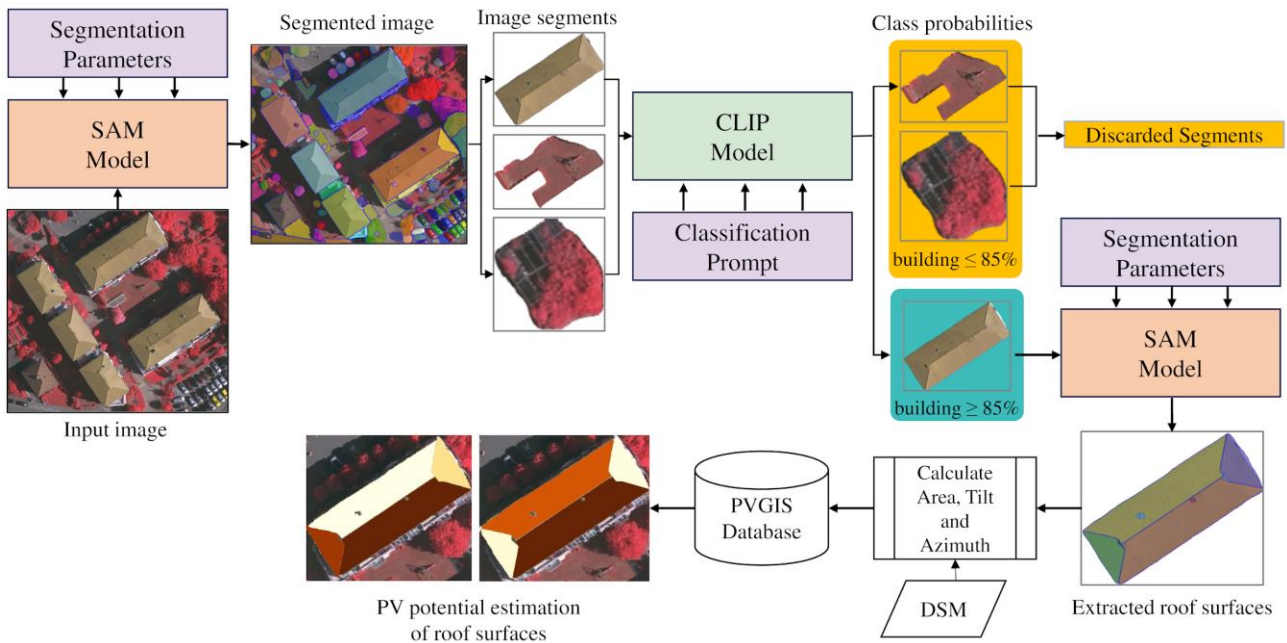


Figure 4. Detection of roof surfaces from aerial photographs and calculation of PV potential

2.2.2. Roof Surface Segmentation from Point Clouds

In the segmentation of roof surfaces from point clouds, we employed SPAN (Özdemir et al., 2023) which has a simple yet highly effective two-step methodology using the well-known and widely used algorithms: Random Sample Consensus (RANSAC) (Fischler & Bolles, 1981) and Density-Based Spatial Clustering of Applications with Noise (DBSCAN) (Ester et al., 1996) (Figure 5).

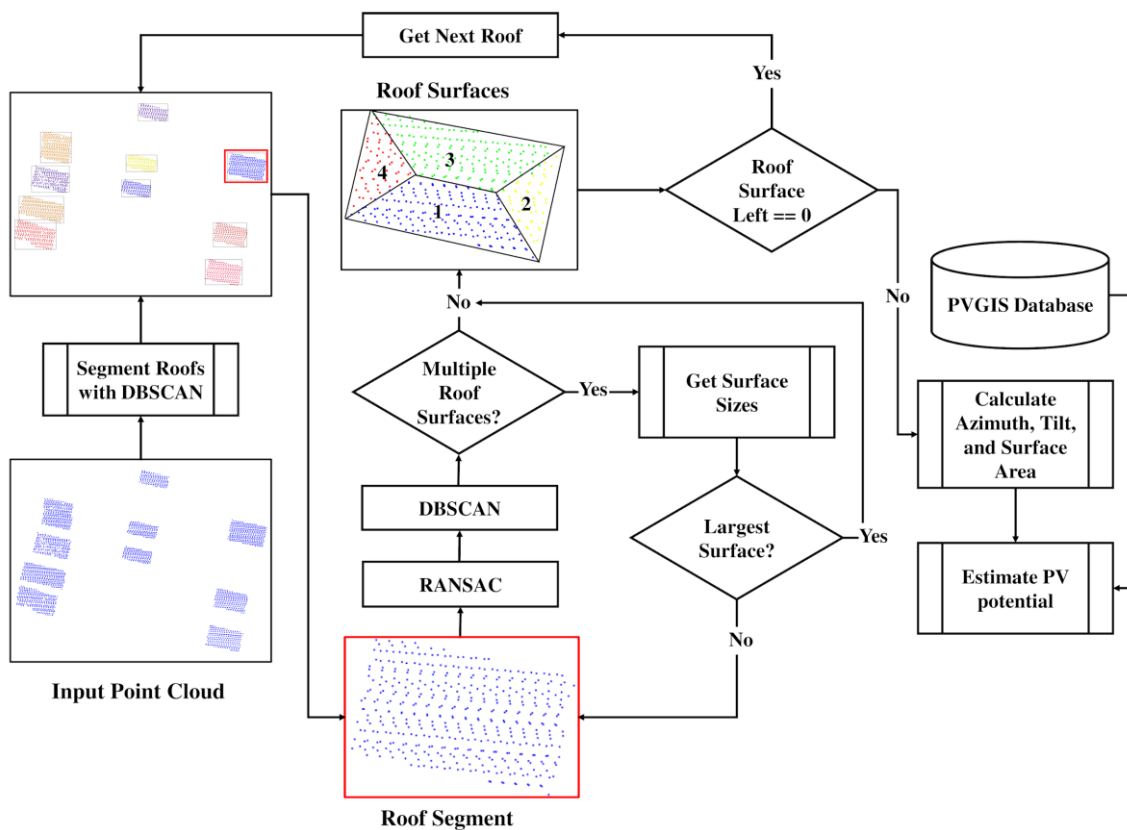


Figure 5. Detection of roof surfaces from point clouds and calculation of PV potential (Özdemir et al., 2023)

In the first step of the SPAN plugin, the input LiDAR point cloud is segmented on a building-by-building basis with the help of the DBSCAN clustering algorithm. This process enables the effective and efficient identification and differentiation of each building at an urban scale. After the building segments are created, the roof surfaces of each building are detected using the RANSAC algorithm. During the phase of separating roof surfaces with the RANSAC algorithm, planes fitting different surfaces of the roof segments are created. However, occasionally, one of the planes generated by RANSAC may overlap with multiple roof segments. In such cases, the DBSCAN clustering algorithm intervenes to determine the largest segment among the overlapping ones. Subsequently, the remaining points are returned to the original point cloud and reprocessed in the next iteration. It's worth noting that the SPAN plugin can only process point clouds containing roof points, which requires prior segmentation of the point clouds.

2.3. PV Potential Analysis

There are various databases, software, and web services available for PV potential analysis, such as PVGIS, Solar Monkey (SM), and Global Solar Atlas. In this study, the PVGIS database developed by the European Commission was utilized, which has been proven to produce results very close to on-site observations (Moudrý et al., 2019; Psiloglou et al., 2020; Suri et al., 2008). PVGIS is a comprehensive and up-to-date database for estimating PV potential, taking into account factors such as surface slope, azimuth, solar panel technology, system loss, and the peak power of the PV panel. The PVGIS database also has the capability to respond to queries containing information such as geographic location, slope, and orientation sent over its Application Programming Interface (API), providing data on Global Horizontal Irradiance (GHI) and PV production.

In this study, the PV potential analysis of roof surfaces detected from aerial photographs and point clouds was conducted using the PVGIS database. For both detection methods, a query file was created by adding solar radiation database information, PV technology, installed peak power, system loss, and economic parameters to the tilt, azimuth, and geographic location information of the detected roof surfaces, and sent to the database. PVGIS servers respond to the query by creating a JSON file that provides comprehensive PV information for each roof surface. The PV potential of each roof surface is calculated using the PV information and the roof surface area obtained from the JSON file.

2.4. Accuracy Assessment

The evaluation of the proposed approaches was conducted by comparing automatically extracted roofs from both aerial imagery and point clouds with reference data, utilizing overall accuracy, precision, recall, F1-score and IoU metrics as shown in Equations (1), (2), (3), (4) and (5).

$$\text{OverallAccuracy} = \frac{(\text{TruePositive} + \text{TrueNegative})}{\text{NumberOfSamples}} \quad (1)$$

$$\text{Precision} = \frac{\text{TruePositive}}{(\text{TruePositive} + \text{FalsePositive})} \quad (2)$$

$$\text{Recall} = \frac{\text{TruePositive}}{(\text{TruePositive} + \text{FalseNegative})} \quad (3)$$

$$\text{F1Score} = \frac{2 * (\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (4)$$

$$\text{IoU} = \frac{\text{TruePositive}}{(\text{TruePositive} + \text{FalsePositive} + \text{FalseNegative})} \quad (5)$$

In Equations (1), (2), and (3), an element identified as an object that matches an object in the reference data is classified as a true positive. An element that matches an object in the reference but is mistakenly classified as background is deemed a false negative. Conversely, an element incorrectly identified as an object when it does not match any object in the reference is considered a false positive. Lastly, a true negative is defined as an element that is correctly identified as background in both the classified and reference data. The Intersection over Union (IoU) metric, also known as the Jaccard Index, quantifies how much the predicted object overlaps with the ground truth object (5).

3. Results

In this section, we thoroughly examine the segmentation results obtained from both developed approaches. Additionally, we evaluate the PV potential analysis outcomes, offering insights into the effectiveness and precision of the methodologies used.

3.1. Roof Surface Segmentation from Aerial Imagery with VFMs

Although the SAM model is trained solely on the RGB (Red, Green, Blue) color space, the segmentation carried out on aerial photographs in the NIR-RGB (Near-Infrared, Green, Blue) color space from the ISPRS Vaihingen dataset has successfully identified many segments according to the model's internal performance metrics, IoU and stability score. The internally calculated segmentation accuracies of the SAM model are approximately 99% IoU and ~98% Stability Score for Study Area 1 and 2. These results demonstrate that the SAM model can effectively detect object segmentation boundaries even in different color spaces.

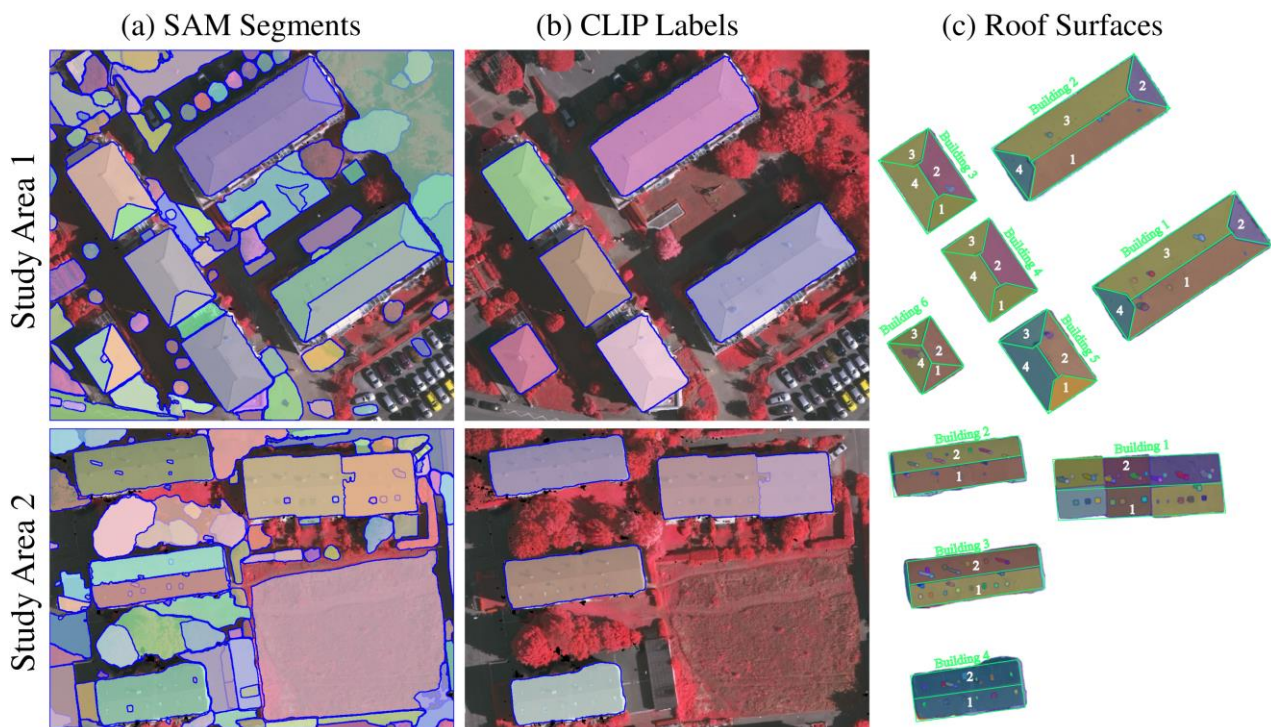


Figure 6. Roof segmentation results: (a) SAM segmentation results, (b) Extracted segments labelled with CLIP, (c) Final roof surfaces extracted with SAM

However, since the SAM model does not possess semantic information about the segments it produces, the identified segments need to be semantically interpreted. At this stage of semantically labeling the SAM segments, the CLIP model was utilized. With CLIP, it was verified whether a segment produced by the SAM model belonged to the roof class or not. Like the SAM model, the CLIP model is also trained only on RGB color space images. However, as shown in Figure 6, CLIP has successfully labeled building segments with approximately 99% Text Probability Score. Moreover, at this stage, it is more clearly visible that the SAM model can almost perfectly detect the actual building boundaries.

Table 1. Roof segmentation accuracy of the SAM and CLIP models

	Study Area 1	Study Area 2
Precision	98.71%	95.00%
Recall	99.21%	99.21%
F1 Score	98.96 %	97.06%
IoU	97.94%	94.29%
Overall Accuracy	99.48%	98.65%

In the last step of the analysis, segments identified as buildings by the CLIP model were reintroduced into the SAM model to carry out the detection of individual roof surfaces and any obstacles present on them. The detected obstacles on the roof surfaces were subsequently removed from the PV potential analysis to improve the accuracy of the estimation. The input images were exclusively composed of building roofs, and the SAM model was specifically conditioned to segment every detail within these images. Under these conditions, the SAM model demonstrated remarkable segmentation capabilities, achieving an overall accuracy exceeding 92.5%, an IoU of 91.2%, and an F1 score of 97.6%.

Table 2. Roof surface segmentation accuracy of the SAM model

	Study Area 1	Study Area 2
Precision	100%	100%
Recall	96.08%	95.36%
F1 Score	97.99%	97.61%
IoU	96.08%	91.23%
Overall Accuracy	92.54%	95.36%

3.2. Roof Surface Segmentation from Point Cloud using Rule Based Approaches

The proposed two-step approach for extracting roof surfaces from point clouds has achieved successful results in identifying roof surfaces within the study areas (Figure 7). This method demonstrated significant effectiveness, achieving an overall accuracy of over 92.5% and an F1 score of more than 90.7%. Additionally, with an accuracy of over 76.0% in the IoU metric, this approach has proven to be highly effective for roof surface segmentation from point clouds (Table 3).

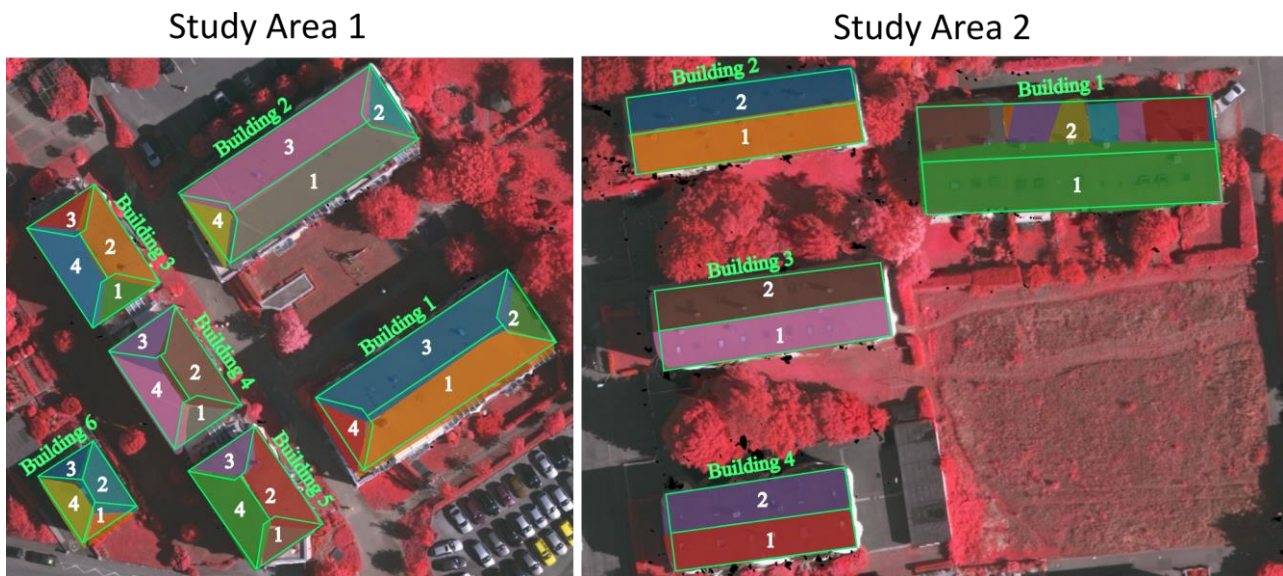


Figure 7. Point cloud roof surface segmentation results

Table 3. Accuracy assessment of roof surface extraction from point cloud

	Study Area 1	Study Area 2
Precision	84.52%	100%
Recall	84.52%	95.36%
F1 Score	90.76%	97.61%
IoU	76.04%	91.23%
Overall Accuracy	92.54%	95.36%

3.3. Photovoltaic Potential Analysis

The PV potential analysis was conducted using the PVGIS database through the PVGIS API. The tilt and azimuth information for each roof surface was calculated from the roof surfaces extracted using the two proposed approaches. For roof surfaces detected from aerial photographs, the tilt and azimuth data were calculated using the DSM, whereas for roof surfaces identified from point clouds, these measurements were directly computed from the point cloud data itself. In the queries sent to the PVGIS database, the PVGIS-SARAH 2 was selected as the solar radiation database. Crystalline Silicon panels, commonly used in current PV panel technology (Ballif et al., 2022; Kettle et al., 2022), were chosen as the installed PV panel. The system loss parameter was set at the default value of 14%. In the queries sent to the PVGIS database, geographic location data for each roof surface was also included. Additionally, the effect of the horizon was considered in calculating the annual PV potential.

In the final stage of the analysis using the SAM model, the roof surfaces obtained were overlaid with the DSM corresponding to the study areas to extract elevation data for each roof surface from the DSM. Subsequently, this elevation data was utilized to separately calculate the slope and azimuth for each of the roof surfaces. The derived slope and azimuth data were then employed to estimate the annual irradiation received by the roof surfaces and the potential PV production values, utilizing the PVGIS database via the PVGIS API (Table 4).

To avoid presenting multiple results of the same roof surface in Table 4 due to the fragmented segmentation of the LiDAR point cloud in Study Area 2 second roof surface of Building 1 we opted to merge the PV estimation results to provide a clearer presentation of the PV potential estimation.

Table 4. Yearly PV output (kWh) of extracted roof surfaces with the SPAN and SAM+CLIP approach

Study Area 1				Study Area 2					
		SAM+CLIP	SPAN	Difference (%)		SAM+CLIP	SPAN	Difference (%)	
Building 1	Surface 1	47608,47	46748,48	1,84	Building 1	Surface 1	77220,97	83968,96	-8,04
	Surface 2	9414,16	6329,61	48,73		Surface 2	64663,95	47604,74	35,84
	Surface 3	43545,17	47245,33	-7,83		Total	141884,92	131573,70	7,84
	Surface 4	9857,67	8317,07	18,52					
	Total	110425,47	108640,49	1,64					
Building 2	Surface 1	47608,47	48581,24	-2,00	Building 2	Surface 1	36731,13	40929,42	-10,26
	Surface 2	9414,16	6726,08	39,96		Surface 2	42866,74	36607,20	17,10
	Surface 3	43545,17	46039,98	-5,42		Total	79597,87	77536,62	2,66
	Surface 4	9857,67	7967,23	23,73					
	Total	110425,47	109314,53	1,02					
Building 3	Surface 1	9521,69	6617,57	43,89	Building 3	Surface 1	36518,81	35596,52	2,59
	Surface 2	17180,84	19324,83	-11,09		Surface 2	43365,19	45332,24	-4,34
	Surface 3	8709,03	5180,83	68,10		Total	79884,00	80928,76	-1,29
	Surface 4	17990,26	18521,33	-2,87					
	Total	53401,82	49644,57	7,57					
Building 4	Surface 1	9527,27	5681,14	67,70	Building 4	Surface 1	55807,46	28638,36	94,87
	Surface 2	17249,18	18942,32	-8,94		Surface 2	-	30269,61	
	Surface 3	8756,91	8934,96	-1,99		Total	55807,46	58907,97	-5,26
	Surface 4	18016,21	14327,13	25,75					
	Total	53549,57	47885,55	11,83					
Building 5	Surface 1	9521,69	5536,21	71,99					
	Surface 2	17180,84	16605,51	3,46					
	Surface 3	8709,03	7416,15	17,43					
	Surface 4	17990,26	18855,86	-4,59					
	Total	53401,82	48413,72	10,30					
Building 6	Surface 1	13238,77	2713,95	387,81					
	Surface 2	-	8968,40	-					
	Surface 3	13099,01	2894,75	352,51					
	Surface 4	-	6880,43	-					
	Total	26337,78	21457,53	22,74					

For both study areas, the two approaches yielded similar results in PV potential estimation regarding overall building PV production. However, inspection of individual roof surfaces revealed greater differences in estimated PV production for some roofs. These discrepancies arise from the characteristics of the data and the methods applied. Point cloud data can more accurately determine the height of objects in the scene, enabling precise determination of azimuth and tilt values. Conversely, accurately identifying object boundaries with linear formations, such as buildings, from point clouds is challenging due to point sampling deficiency. Additionally, fitting a plane to a roof surface using the RANSAC algorithm sometimes results in surfaces that do not exactly match the actual roof. In image-based roof surface extraction, limitations such as occlusions and shadows affect accuracy. Occlusions lead to inevitable loss of surface boundaries, while shadowed roof segments were relatively successfully handled by the SAM. Despite these setbacks, both approaches estimated PV potential values within a 20% discrepancy, with most buildings exhibiting even lower differences.

4. Discussion

The integration of the SAM and CLIP models has enabled for accurate detection of building rooftops, their individual surfaces, and obstacles such as chimneys and windows, thereby providing a more precise basis for PV potential analysis. The SAM, trained on terrestrial RGB imagery, was successfully applied to aerial imagery in BGNIR format and achieved notable accuracy metrics for two different study areas. Specifically, for Study Area 1 and Study Area 2, roof and obstacle segmentation were completed with 92.54% and 95.36% overall accuracy, 96.08% and 91.23% IoU, and 97.99% and 97.61% F1 scores, respectively. However, obstacles like chimneys sometimes included shadowed areas, slightly reducing the accuracy of surface area calculations. Optimal parameterization of the SAM model and the resolution of the input images, as well as careful prompt selection for the CLIP model, were found to be critical for achieving these performance levels. In terms of runtime, SAM required approximately one minute per image to complete segmentation using a T4 GPU (including module and image loading), while Open CLIP completed segmentation in about two seconds per image segment on an A100 GPU and seven seconds on a T4 GPU.

The RANSAC algorithm within the SPAN plugin was similarly effective for point cloud segmentation. It achieved comparable accuracy and quality metrics—with 92.54% and 95.36% overall accuracy, 76.04% and 91.23% IoU, and 90.76% and 97.61% F1 scores for Study Area 1 and Study Area 2, respectively—demonstrating that it is both a reliable and computationally efficient method. However, factors like low point density and outliers on certain building roofs can negatively impact its accuracy. Results may be improved by employing higher-density point clouds or pre-processing steps to remove outliers. Unlike many existing methods that treat an entire building as a single roof surface and thus rely on a uniform tilt angle and azimuth, our approach evaluates each roof surface separately. This refinement enhances the accuracy of PV potential analyses and highlights the ability of the SPAN plugin for more accurate and detailed rooftop segmentation.

5. Conclusion

The proposed methods demonstrated a high level of effectiveness in PV potential analysis derived from both aerial imagery and LiDAR point clouds. The approach utilizing the SAM and CLIP successfully delineated rooftop surfaces and identified obstacles, enabling a more accurate estimation of PV potential. This outcome highlights the capacity of VFMs to support complex tasks, such as obstacle detection on rooftop surfaces. Similarly, the point cloud-based method efficiently extracted roof surfaces, reinforcing its potential as a reliable and robust alternative.

Future research will focus on refining VFM-based rooftop extraction and minimizing reliance on auxiliary data for determining surface azimuth and tilt. This objective will be pursued by integrating VFM-based depth estimation methods. In parallel, considering the increasing accessibility and precision of LiDAR data, particularly its capacity to penetrate canopy cover, we plan to enhance the generalizability of the proposed workflow through the incorporation of deep learning strategies. Such improvements are expected to further advance the accuracy, scalability, and adaptability of PV potential assessments in diverse urban environments.

References

- Akumu, C. E., & Dennis, S. (2023). Exploring the addition of airborne LiDAR-DEM and derived TPI for urban land cover and land use classification and mapping. *Photogrammetric Engineering & Remote Sensing*, 89(1), 19–26.
- Ballif, C., Haug, F.-J., Boccard, M., Verlinden, P. J., & Hahn, G. (2022). Status and perspectives of crystalline silicon photovoltaics in research and industry. *Nature Reviews Materials*, 7(8), 597–616.

- Comert, R., & Kaplan, O. (2018). Object-based building extraction and building period estimation from unmanned aerial vehicle data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4(3), 71–76. <https://doi.org/10.5194/isprs-annals-IV-3-71-2018>
- Cramer, M. (2010). The DGPF-test on digital airborne camera evaluation: Overview and test design. *Photogrammetrie-Fernerkundung-Geoinformation*, 2, 73–82.
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996, August 2–6). A density-based algorithm for discovering clusters in large spatial databases with noise [Conference presentation]. 2nd International Conference on Knowledge Discovery and Data Mining, Portland, Oregon.
- Fischler, M. A., & Bolles, R. C. (1981). Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6), 381–395.
- Hansch, R., & Hellwich, O. (2021). Fusion of multispectral LiDAR, hyperspectral, and RGB data for urban land cover classification. *IEEE Geoscience and Remote Sensing Letters*, 18(2), 366–370.
- Huang, X., Hayashi, K., Matsumoto, T., Tao, L., Huang, Y., & Tomino, Y. (2022). Estimation of rooftop solar power potential by comparing solar radiation data and remote sensing data—A case study in Aichi, Japan. *Remote Sensing*, 14(7), Article 1742. <https://doi.org/10.3390/rs14071742>
- Kavzoglu, T., Colkesen, I., Atesoglu, A., Tonbul, H., Yilmaz, E. O., Ozlusoylu, S., & Ozturk, M. Y. (2024). Construction and implementation of a poplar spectral library based on phenological stages for land cover classification using high-resolution satellite images. *International Journal of Remote Sensing*, 45(6), 2049–2072.
- Kettle, J., Aghaei, M., Ahmad, S., Fairbrother, A., Irvine, S., Jacobsson, J. J., Kazim, S., Kazukauskas, V., Lamb, D., Lobato, K., Mousdis, G. A., Oreski, G., Reinders, A., Schmitz, J., Yilmaz, P., & Theelen, M. J. (2022). Review of technology-specific degradation in crystalline silicon, cadmium telluride, copper indium gallium selenide, dye-sensitised, organic and perovskite solar cells in photovoltaic modules: Understanding how reliability improvements in mature technologies can enhance emerging technologies. *Progress in Photovoltaics: Research and Applications*, 30(12), 1365–1392. <https://doi.org/10.1002/pip.3577>
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). *Segment anything*. arXiv. <http://arxiv.org/abs/2304.02643>
- Lan, H., Gou, Z., & Xie, X. (2021). A simplified evaluation method of rooftop solar energy potential based on image semantic segmentation of urban streetscapes. *Solar Energy*, 230, 912–924.
- Li, S. Y., & Han, J. Y. (2022). The impact of shadow covering on the rooftop solar photovoltaic system for evaluating self-sufficiency rate in the concept of nearly zero energy building. *Sustainable Cities and Society*, 80, Article 103821. <https://doi.org/10.1016/j.scs.2022.103821>
- Ma, H., Ma, H., Zhang, L., Liu, K., & Luo, W. (2022). Extracting urban road footprints from airborne LiDAR point clouds with PointNet++ and two-step post-processing. *Remote Sensing*, 14(3), Article 789. <https://doi.org/10.3390/rs14030789>
- Mao, H., Chen, X., Luo, Y., Deng, J., Tian, Z., Yu, J., Xiao, Y., & Fan, J. (2023). Advances and prospects on estimating solar photovoltaic installation capacity and potential based on satellite and aerial images. *Renewable and Sustainable Energy Reviews*, 179, Article 113276. <https://doi.org/10.1016/j.rser.2023.113276>
- Minelli, F., D’Agostino, D., Migliozi, M., Minichiello, F., & D’Agostino, P. (2023). PhoVer: a modular and integrated tracking photovoltaic shading device for sustainable large urban spaces—preliminary study and prototyping. *Energies*, 16(15), Article 5786. <https://doi.org/10.3390/en16155786>
- Moudrý, V., Beková, A., & Lagner, O. (2019). Evaluation of a high-resolution UAV imagery model for rooftop solar irradiation estimates. *Remote Sensing Letters*, 10(11), 1077–1085.
- Özdemir, S., Akbulut, Z., Karsli, F., & Acar, H. (2021). Automatic extraction of trees by using multiple return properties of the LiDAR point cloud. *International Journal of Engineering and Geosciences*, 6(1), 20–26.
- Özdemir, S., Yavuzdoğan, A., Bilgilioğlu, B. B., & Akbulut, Z. (2023). SPAN: An open-source plugin for photovoltaic potential estimation of individual roof segments using point cloud data. *Renewable Energy*, 216, Article 119022. <https://doi.org/10.1016/j.renene.2023.119022>
- Ozturk, O., Isik, M. S., Sariturk, B., & Seker, D. Z. (2022). Generation of Istanbul road data set using Google Map API for deep learning-based segmentation. *International Journal of Remote Sensing*, 43(8), 2793–2812.
- Ozturk, O., Isik, M. S., Kada, M., & Seker, D. Z. (2023). Improving road segmentation by combining satellite images and LiDAR data with a feature-wise fusion strategy. *Applied Sciences*, 13(10), Article 6161. <https://doi.org/10.3390/app13106161>
- Psiloglou, B. E., Kambezidis, H. D., Kaskaoutis, D. G., Karagiannis, D., & Polo, J. M. (2020). Comparison between MRM simulations, CAMS and PVGIS databases with measured solar radiation components at the Methoni station, Greece. *Renewable Energy*, 146, 1372–1391. <https://doi.org/10.1016/j.renene.2019.07.064>

- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askeel, A., Mishkin, P., Clark, J., Krueger, G., & Sutskever, I. (2021). *Learning transferable visual models from natural language supervision*. arXiv. <http://arxiv.org/abs/2103.00020>
- Ranald, L., Busch, H., Hansen, T., Brommer, M., Couture, T., Gibb, D., ... & Sverrisson, F. (2021). *Renewables in cities: 2021 global status report*. REN21 Secretariat. https://www.ren21.net/wp-content/uploads/2019/05/GSR2021_Full_Report.pdf
- Sahak, A. S., Karsli, F., Gormus, E. T., & Ahmadi, K. (2023). Seasonal monitoring of urban heat island based on the relationship between land surface temperature and land use/cover: A case study of Kabul City, Afghanistan. *Earth Science Informatics*, 16(1), 845–861.
- Stack, V., & Narine, L. L. (2022). Sustainability at Auburn University: Assessing rooftop solar energy potential for electricity generation with remote sensing and GIS in a Southern US campus. *Sustainability*, 14(2), Article 626. <https://doi.org/10.3390/su14020626>
- Suri, M., Huld, T., Cebecauer, T., & Dunlop, E. D. (2008). Geographic aspects of photovoltaics in Europe: Contribution of the PVGIS website. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 1(1), 34–41. <https://doi.org/10.1109/JSTARS.2008.2001431>
- Tonbul, H., & Kavzoglu, T. (2020). Semi-automatic building extraction from WorldView-2 imagery using Taguchi optimization. *Photogrammetric Engineering & Remote Sensing*, 86(9), 547–555.
- Topaloğlu, R. H., Aksu, G. A., Ghale, Y. A. G., & Sertel, E. (2022). High-resolution land use and land cover change analysis using GEOBIA and landscape metrics: A case of Istanbul, Turkey. *Geocarto International*, 37(25), 9071–9097.
- Yagmur, N., Dervisoglu, A., & Bilgilioğlu, B. (2022). Assessment of rapid urbanization effects with remote sensing techniques. In M. Ben Ahmed, A. A. Boudhir, İ. R. Karas, V. Jain, & S. Mellouli (Eds.), *Innovations in Smart Cities Applications* (pp. 571–585). https://doi.org/10.1007/978-3-030-94191-8_46
- Zhao, J., He, X., Li, J., Feng, T., Ye, C., & Xiong, L. (2019). Automatic vector-based road structure mapping using multibeam LiDAR. *Remote Sensing*, 11(14), Article 14. <https://doi.org/10.3390/rs11141726>
- Zhong, T., Zhang, Z., Chen, M., Zhang, K., Zhou, Z., Zhu, R., Wang, Y., Lü, G., & Yan, J. (2021). A city-scale estimation of rooftop solar photovoltaic potential based on deep learning. *Applied Energy*, 298, Article 117132. <https://doi.org/10.1016/j.apenergy.2021.117132>