



Received: 26 December 2022 | Revised: 18 June 2023 | Accepted: 19 June 2023

GÜZELHİSAR HAVZASINDA ENDÜSTRİYEL GELİŞMENİN ARAZİ ÖRTÜSÜ VE ARAZİ KULLANIMI ÖZELLİKLERİ ÜZERİNDEKİ ETKİSİNİN BULUT TABANLI MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE DEĞERLENDİRİLMESİ

Assessing Industrial Development Influence on Land Use and Land Cover Change Detection in Güzelhisar Basin with Cloud-Based Machine Learning Techniques

Şevki DANACIOĞLU¹

İzmir Bakırçay Üniversitesi, Coğrafya Bölümü,
İzmir-Türkiye
sevki.danacioglu@bakircay.edu.tr

Hüseyin Can ÖNGÜL

İzmir Bakırçay Üniversitesi, Lisansüstü Eğitim Enst.
Coğrafya Anabilim D., İzmir-Türkiye
huseyincan.ongul@bakircay.edu.tr

Abstract

Industrial activity is the main driving force behind urban growth, influencing the socioeconomic status of an area by creating employment opportunities. Land use and land cover (LULC) are influenced by various factors such as ecological conditions, geological and geomorphological features, vegetation characteristics, and socioeconomic structure. Monitoring LULC changes, their intensity, direction, and underlying causes provides valuable knowledge for sustainable development planning. Remote sensing (RS) is widely considered the most cost-effective and practical approach for obtaining regional and global LULC information. The aim of this study is to investigate the impact of industrial activity on LULC in the Güzelhisar Basin. Using satellite imagery and machine learning algorithms, the LULC status from 1995 to 2022 was determined. The LULC classes were classified as 'Water Surface', 'Forest Area', 'Agricultural Area', 'Bare Surface', and 'Built-Up Area'. The research utilized LANDSAT satellite images with a 30-meter resolution. To enhance accuracy, various indices including the NDVI, SAVI, NDWI, NBLI, BSI, and NDBI were calculated for the years 1995 and 2022. The Random Forest (RF) machine learning algorithm was employed for satellite image classification. The Google Earth Engine (GEE) platform was utilized for image acquisition and classification. Classification accuracy was evaluated using the Error Matrix, User's Accuracy, Producer's Accuracy, Overall Accuracy, and Kappa Coefficient. The findings indicate a significant increase in built-up areas and a decrease in agricultural and bare areas within the survey area. This demonstrates the impact of industrial operations on urbanization, considering the amount of increase in anthropic surfaces. The study thoroughly evaluates the capabilities of the GEE platform, machine learning-based classification algorithm, and the entire process from image classification to the assessment of obtained findings. These findings are crucial for future studies and the broader implementation of open data sources and cloud-based platforms in RS and Geographic Information Systems research.

Keywords: Güzelhisar Basin, Remote Sensing, Google Earth Engine, Random Forest, Land Use and Land Cover Change

Öz

Endüstriyel faaliyetin varlığı, kentsel büyümenin ana itici gücüdür ve istihdam fırsatları yaratarak bölgenin sosyoekonomik durumunu etkilemektedir. Arazi Örtüsü ve Arazi Kullanımı (AÖAK), ekolojik koşullar, jeolojik ve jeomorfolojik özellikler, bitki örtüsü özellikleri gibi biyotik ve abiyotik faktörler ile sosyoekonomik yapı tarafından etkilenmektedir. AÖAK değişimlerini, bunların yoğunluğunu, değişim yönünü, etkenlerini ve izlemek, sürdürülebilir kalkınma planlaması için önemli bilgiler sağlamaktadır. Uzaktan Algılama (UA), bölgesel ve küresel AÖAK bilgisi elde etmek için en ekonomik ve uygulanabilir yaklaşım olarak kabul edilmektedir. Çalışmanın amacı Güzelhisar Havzasında sanayi faaliyetlerinin AÖAK durumu üzerindeki etkisini araştırmaktır. Bu bağlamda uydu görüntüleri kullanarak makine öğrenme algoritması ile 1995-2022 yıllarına ait AÖAK durumu tespit edilmiştir. Sınıflandırmada AÖAK sınıfları 'Su Yüzeysi', 'Orman Alanı', 'Tarım Alanı', 'Açık Yüzeys' ve 'Beşeri Yüzeys' olarak belirlenmiştir. Araştırmada 30 m çözünürlüğü ile LANDSAT uydu görüntüleri kullanılmıştır. Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Toprakla Düzeltilmiş Bitki Örtüsü İndeksi (SAVI), Normalize Edilmiş Fark Su İndeksi (NDWI), Normalize Edilmiş Açık Yüzeys İndeksi (NBLI), Çıplak Toprak İndeksi (BSI), Normalize Edilmiş Fark Yerleşim Alanı İndeksi (NDBI) indeksleri 1995 ve 2022 yılları için hesaplanarak doğruluğu artırmak amacıyla kullanılmıştır. Uydu görüntülerinin sınıflandırmasında Rastgele Orman (RF) makine öğrenme algoritması tercih edilmiştir. Görüntülerin elde edilmesinde ve sınıflandırma işlemlerinde Google Earth Engine (GEE) platformu kullanılmıştır. Sınıflandırma doğruluğu hata matrisi, kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve Kappa Katsayısı ile hesaplanmıştır. Sonuç olarak araştırma sahasında beşeri yüzeylerde önemli miktarda artış meydana gelirken, tarım alanlarında ve açık yüzeylerde azalma olduğu tespit edilmiştir. Beşeri yüzeylerdeki artış miktarı dikkate alındığında bölgede sanayi faaliyetlerine bağlı istihdam potansiyelinin kentleşme üzerindeki etkisini göstermektedir. Araştırma kapsamında GEE platformunun yetenekleri, makine öğrenmesine dayalı sınıflandırma algoritması, sınıflandırma süreçleri ve elde edilen

¹ Sorumlu Yazar/ Corresponding author

bulguların değerlendirilmesine kadar olan tüm süreç performansları değerlendirilmiştir. Bu açıdan çalışmanın tüm sonuçları, gelecekte yapılacak çalışmaların geliştirilmesi, ayrıca UA ve Coğrafi Bilgi Sistemleri araştırmalarında açık veri kaynaklarının ve bulut tabanlı platformların yaygınlaşması açısından önem arz etmektedir.

Anahtar Kelimeler: Güzehisar Havzası, Uzaktan Algılama, Google Earth Engine, Makine Öğrenmesi, Arazi Kullanımı ve Arazi Örtüsü

1. GİRİŞ

Sanayileşmiş veya sanayileşmekte olan ülkelerde meydana gelen ve günümüzde halen devam etmekte olan kontrolsüz büyüme önemli çevresel etkilere neden olmaktadır. Geçtiğimiz yüzyılda sanayileşme ve buna bağlı olarak gelişen insan faaliyetleri, çevresel kirlilik, plansız kentleşme ve tarım alanlarının amaç dışı kullanımı gibi sorunları beraberinde getirmiştir (Simmons, 2008). Bir yandan verimli tarım arazileri sanayi faaliyetleri kapsamında amaç dışı kullanılmakta, diğer yandan bu faaliyetlere bağlı olarak toprak, su ve hava kirliliği gibi çeşitli sorunlar ortaya çıkabilmektedir. Sanayi faaliyetlerinin neden olduğu bu etkiler genellikle faaliyetin büyüklüğünden çok, planlama ve özellikle yer seçimindeki yanlış kararlardan kaynaklanmaktadır (Tanrıvermiş ve Mülâyim, 1999). Diğer yandan endüstriyel faaliyetin varlığı, kentsel büyümenin ana itici gücüdür ve istihdam fırsatları yaratarak bölgenin sosyoekonomik durumunu etkilemektedir (Hayter, 1997).

Sanayi faaliyetlerinin gelişmesiyle birlikte nüfus ve arazi kullanım faaliyeti olarak kentsel alanların genişlemesi sürekli değişim göstermektedir (Balchin vd., 2000). Endüstriyel faaliyetler, hem doğrudan hem de nüfus artışı ve buna bağlı olarak gelişen diğer faaliyetlerin etkisiyle Arazi Örtüsü ve Arazi Kullanımı (AÖAK) üzerinde etkili olmaktadır (Geenhuizen ve Nijkamp, 1995). AÖAK değişimi, insan ve biyofiziksel kuvvetlerin AÖAK üzerindeki etkilerini anlamak ve bu değişikliklerin çevresel ve sosyal etkilerini ortaya koymak gibi çok yönlü etkilere sahiptir. Nitekim AÖAK, büyük ölçüde ekolojik koşullar, jeolojik ve jeomorfolojik özellikler gibi biyotik ve abiyotik faktörler ile birlikte arazi kullanım modelini etkileyen teknolojik, sosyoekonomik ve yönetsel yapı tarafından belirlenmektedir (Rai vd., 1994).

AÖAK haritalaması, herhangi bir alanın doğal kaynak planlama ve yönetim programları için çok önemlidir. AÖAK değişiklikleri tam olarak arazinin bozulması anlamına gelmese de küresel ölçekteki çevresel değişikliklerin en önemli itici güçlerinden biridir (Lambin, 1999). Bu durum doğal ekosistemler üzerinde önemli etkilere sahiptir. Araştırmalar AÖAK değişiminin iklim, biyoçeşitlilik, erozyon, gıda güvenliği ve ekosistemlerin sosyoekonomik kırılganlığı gibi sorunlar üzerinde etkili olduğunu göstermektedir (Turner vd., 2007; Salazar vd., 2015; Yang vd., 2017; Gashaw vd., 2018; Atumane ve Cabral, 2021).

AÖAK değişimlerini, bunların yoğunluğunu, değişim yönünü, etkenlerini ve etkilerini anlamak ve izlemek, sürdürülebilir kalkınma planlaması için önemli bilgiler sağlamaktadır (Loveland vd., 2002). Uzaktan Algılama (UA) teknolojisi ile birlikte Coğrafi Bilgi Sistemleri (CBS), karar vericilere bilimsel olarak güvenilir sonuçlar ve politika önerileri sağlamaktadır (Rojan ve Chen, 2004). UA teknolojileri ile farklı ölçeklerde arazi örtüsü ürünleri, 1972'de LANDSAT-1 ile başlayan uydu misyonlarının sinoptik ve periyodik gözlemleri ile mümkün olmuştur (Belward ve Skøien, 2015). UA sensörleri, bir kara yüzeyinin elektromanyetik özelliklerini (yansıyan enerji (optik sensörler), yayılan (termal kızılötesi veya pasif mikrodalga sensörleri) veya saçılan (aktif radar sensörleri) kaydeden çeşitli temel fiziksel ilkeler üzerinde çalışır ve bu nedenle, arazi özellikleri hakkında çeşitli bilgiler sağlamaktadır. Bununla birlikte UA verilerini kullanarak AÖAK haritalarının oluşturulması konularında çeşitli zorluklar bulunmaktadır. Örneğin UA verisi üzerinden elde edilen arazi bilgisi, gerçek kullanım hakkında doğru bilgi veremeyebilir. Nitekim AÖAK bilgisi genellikle yer bilgisi veya kullanıcı yorumu ile ilişkili olarak elde edilebilmektedir (Giri, 2012).

Bununla birlikte UA, bölgesel ve küresel AÖAK bilgisi elde etmek için en ekonomik ve uygulanabilir yaklaşım olarak kabul edilmektedir (Cihlar, 2000). AÖAK bilgilerini UA verilerinden haritalamak için çeşitli sınıflandırma algoritmaları kullanılmaktadır. UA verilerinin sınıflandırmasında makine öğrenmesi yaklaşımları çeşitliliği ve sağlamlıklarından dolayı yaygın bir şekilde kullanılmaktadır (Kotsiantis, 2007; Lary vd., 2016; Hu vd., 2018, Xie vd., 2019; Pan vd., 2022). Makine öğrenmesi, kontrollü, kontrolsüz, yarı kontrollü ve takviyeli olarak ayrı ayrı kategorilerde incelenmektedir. UA alanında en sık kullanılan kontrolsüz sınıflandırma yöntemleri, K-Ortalamalar, ISODATA, Bulanık K-ortalamalar, Öz örgütlemeli haritalar (SOM) yapay sinir ağı yöntemleridir (Danacıoğlu, 2019). Yaygın olarak kullanılan kontrollü sınıflandırma yöntemleri ise Maksimum

olabilirlik, K- en yakın komşu (KNN), Destek vektör makineleri (SVM) ve Rastgele orman (RF) sınıflandırıcısı gibi yöntemlerdir (Li vd., 2014).

Son yıllarda çeşitli programlama dillerine dayalı örüntü tanıma ve yapay zekâ algoritmalarında önemli gelişmeler meydana gelmiştir. Yapay zekâ uygulamalarından biri olan makine öğrenmesi, UA verileri gibi yüksek boyutlu verilerde örüntü tanıma için otomatik bir endüktif yaklaşım kullanmaktadır (Maxvell vd., 2018). Makine öğrenmesi algoritmalarının birincil yeteneği, yüksek boyuttaki karmaşık veri kümelerini işleyerek ve bunları belirli özellikleri olan sınıflara eşlemesidir. Diğer bir ifadeyle makine öğrenmesi sınıflandırma algoritmaları, veriye dayalı güçlü bir yaklaşım setidir (Cracknell ve Reading 2014). Bu kapsamda makine öğrenmesi algoritmaları UA kapsamında heyelan riskinin hesaplanması (Hejar vd., 2019; Prakash vd., 2020), tarımsal kuraklık (Khan vd., 2020; Liu vd., 2020), hava kirliliği (Bozdağ vd., 2020), toprak tuzluluğu (Taghizadeh-Mehrjardi vd., 2020) ve yeraltı suyu potansiyeli (Arabameri vd., 2019) gibi çeşitli konularda yaygın olarak kullanılmaktadır.

Bu çalışmanın amacı Güzelhisar Havzasında sanayi faaliyetlerine bağlı olarak bölgede artan insan baskısının AÖAK durumu üzerindeki etkisini ortaya koymaktır. Bu bağlamda uydu görüntüleri kullanarak bulut tabanlı makine öğrenme algoritması ile Aliğa Organize Sanayi Bölgesi (AOSB) baskısı altında olan Güzelhisar Havzasının güncel ve AOSB öncesi, 1995-2022 yıllarına ait AÖAK durumu tespit edilmiştir. Buna bağlı olarak araştırmada; (1) Güzelhisar Havzasında 1995-2022 yıllarına ait AÖAK durumlarında nasıl bir değişim olmuştur? (2) Havzada AÖAK durumları üzerinde sanayi faaliyetleri ve buna bağlı olarak kentleşmenin etkisi nasıldır? (3) Varsa, bu etki araştırma sahasının hangi bölümlerinde daha fazladır? sorularına cevap aranmıştır.

2. MATERYAL VE YÖNTEM


2.1. Çalışma Alanı

Güzelhisar Çayı havzası Ege Bölgesi'nin kıyı Ege bölümünde bulunan, İzmir İline bağlı Aliğa, Menemen, Bergama ile Manisa merkez ilçe sınırlarına kadar uzanan bir havzadır (Şekil 1). Coğrafi olarak kabaca 38° 40' ve 38° 60' Kuzey ile 26° 45' ve 27° 25' Doğu koordinatları arasında yer almaktadır. Güzelhisar Çayı Aliğa ilçe sınırlarında bulunan en büyük akarsudur. Kaynağını Yunt Dağından alan Güzelhisar Çayı, yıl boyunca akış göstermektedir, Kocaçay ve Sirce çaylarının birleştiği noktadan itibaren Güzelhisar adını almaktadır. Bütün kolları ile 70 km uzunluğa sahip Güzelhisar Çayı'nın debisi ortalama olarak 3,71 m³/sn'dir (Bayırhan ve Nas, 2018). Topoğrafik olarak Güzelhisar havzası, doğuda Yunt Dağı, batı yönünde Çandarlı Körfezi, güneyde Dumanlı Dağ ve kuzeyde ise Bakırçay Havzası ile sınırlanmıştır.

Araştırma sahası Bakırçay ve Gediz Havzaları arasında kabaca doğu-batı doğrultusunda üçgen şeklinde uzanmaktadır. Yunt Dağı'nın batı kesiminde, Çandarlı Körfezi'ne kadar olan bölgeyi kapsayan havzada, ana hatlarıyla kuzeydoğu-güneybatı yönünde uzanan yüksek rölyefli alanlar ile havzanın batısında yer alan çöküntü alanlarının oluşturduğu iki büyük jeomorfolojik ünite yer almaktadır (Eroğlu ve Bozyiğit, 2011). Bölgede dağlık tepelik alanlar ile plato sahası yüksek rölyefi; faylanarak çöken sahaların oluşturduğu graben alanları, delta sahası ve kıyılar alçak rölyefi oluşturmaktadır (Şekil 2). Günümüzde iki farklı ilin, dört farklı ilçesine ait 49 köy yerleşmesinin ve AOSB'nin içerisinde yer alan Güzelhisar Havzası'nda gerçekleştirilen beşerî faaliyetler, söz konusu bu yapısal unsurlar ve morfolojik şekiller tarafından önemli ölçüde denetlenmektedir (Eroğlu ve Bozyiğit, 2011).


Güzelhisar Havzasında AÖAK büyük ölçüde Türkiye'nin en büyük sanayi bölgesi olan Aliğa Organize Sanayi Bölgesi (AOSB) ve buna bağlı olarak artan nüfus ile birlikte kentleşme süreçleri tarafından belirlenmektedir. 1960'lı yıllara kadar tarım yönünden gelişmiş olan bölgede 1961 yılında "Ağır Sanayi Bölgesi" kurulmasına karar verildikten sonra, 1970'lerin başından itibaren sanayi ağırlıkta olan bir ekonomik karakter ortaya çıkmıştır (Bayırhan ve Nas, 2018). Yörede PETKİM ve TÜPRAŞ gibi kamu kuruluşlarının tesisler kurması, sanayileşme sürecini hızlandırmıştır. Diğer yandan Güzelhisar Çayı ve üzerinde kurulu Güzelhisar Barajı, suya ihtiyaç duyan petrokimya endüstrisi ve demir-çelik fabrikalarını da bölgeye çekmektedir. Nitekim Petrol Ofisi, Türkiye'nin en büyük petrokimya endüstrisi, demir-çelik fabrikaları ve çeşitli sıvılaştırılmış gaz

dolum tesislerinin bölgede toplanması Aliğa'nın bir sanayi kenti haline gelmesine neden olmuştur (Bayırhan ve Nas, 2018).



Şekil 1- Güzelhisar Çayı Havzası Konum Haritası

Figure 1- Location Map of Güzelhisar Basin



Şekil 2- Güzelhisar Havzası Topoğrafya Haritası

Figure 2- Topography Map of Güzelhisar Basin

2.2. Veri

AOSB, 1997 yılı yatırım programında “Sanayi Bakanlığında kredi kullanmadan kurulacak Organize Sanayi Bölgesi” olarak yer almış ve yaklaşık 10 Milyon m² alanda kurulmuştur (Aliğa Organize Sanayi Bölgesi

Kurumsal Bilgi, [AOSBKİ], 2022). Bu kapsamda araştırmanın zamansal ölçeği AOSB öncesi 1995 yılı Ağustos ayı ile 2022 Ağustos ayı olarak belirlenmiştir. Araştırmanın mekânsal ölçeği ise bant çözünürlüğü olan 30 metre olarak belirlenmiştir. Görüntüler, USGS (Birleşik Devletler Jeoloji Araştırmaları Kurumu) tarafından sağlanan geometrik ve radyometrik düzeltmeleri yapılmış görüntüler Google Earth Engine (GEE) platformu kullanılarak temin edilmiştir. Araştırmada en fazla %5 bulutluluğa sahip, atmosferik olarak düzeltilmiş LANDSAT 5 TM ve LANDSAT 8 OLI görüntüleri tercih edilmiştir (Tablo 1). Buna göre araştırmada 1995 yılı için 05.08.1995 ile 14.08.1995 tarihlerine ait görüntülerinden elde edilen medyan görüntü; 2022 yılı için 22.08.2022 tarihine ait görüntü kullanılmıştır.

Tablo 1- Kullanılan Uydu Görüntülerinin Bant Özellikleri.

Table 1- Band Properties of Used Satellite Images

Veri Katmanı	Kaynak	Kullanılan Bantlar	Bant Genişliği (µm)	Mekânsal Çözünürlük (m)
LANDSAT-5 Level 2.	Google Earth Engine aracılığıyla USGS	Bant 1 (Blue)	0.45-0.52	30
		Bant 2 (Green)	0.52-0.60	30
		Bant 3(Red)	0.63-0.69	30
		Bant 4 (NIR)	0.77-0.90	30
		Bant 5 (SWIR1)	1.55-1.75	30
		Bant 7 (SWIR2)	2.08-2.35	30
		LANDSAT-8 OLI Level 2.	Google Earth Engine aracılığıyla USGS	Bant 1 (Aerosol)
Bant 2 (Blue)	0.452-0.512			30
Bant 3 (Green)	0.533-0.590			30
Bant 4 (Red)	0.636-0.673			30
Bant 5 (NIR)	0.851-0.879			30
Bant 6 (SWIR1)	1.566-1.651			30
Bant 7 (SWIR2)	2.107-2.294			30

Araştırmada sınıflandırma doğruluğunu artırmak için çeşitli UA indeksleri kullanılarak ikincil veriler elde edilmiştir. UA indeksleri, birden fazla veri setine ait spektral özelliklerin nicel olarak birlikte ele alınmasına izin vermektedir. Böylece coğrafi nesnelere ait bilgiler, araştırmacı yanlılığından uzak ve hızlı bir şekilde analiz edilmekte ve değerlendirilmektedir (Viana vd., 2019; Ge vd., 2020 Javed vd., 2021). Bu kapsamda araştırmada kentsel alanların, bitki örtüsü yüzeylerinin ve su yüzeylerinin belirlenmesinde sınıflandırma doğruluğunun artırmak amacıyla çeşitli UA indeksleri kullanılmıştır (Tablo 2).

Tablo 2- Sınıflandırma Kullanılan UA İndeksleri

Table 2- RS Indices Used in the Classification

İndeks Adı	Bantlar	Formül	Açıklama	Kaynak
Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI)	RED, NIR	$(NIR-RED) \div (NIR+RED)$	Bitki örtüsü yoğunluğu.	(Colwell, 1974)
Toprakla Düzeltilmiş Bitki Örtüsü İndeksi (SAVI)	RED, NIR	$(1.0 + L) * (NIR - RED) / (NIR + RED + L)$ $(2.0 L=0.5)$	Bitki örtüsü yoğunluğu.	(Huete, 1988)
Normalize Edilmiş Fark Su İndeksi (NDWI)	GREEN, NIR	$(NIR-GREEN) \div (NIR+GREEN)$	Su yüzeylerinin tespiti.	(McFeeters, 1996)
Normalize Edilmiş Açık Yüzeyi İndeksi (NBLI)	RED, THERMAL1	$(RED - THERMAL1) \div (RED + THERMAL1)$	Toprak yüzeylerinin tespiti	(Li vd., 2017)
Çıplak toprak indeksi (BSI)	RED, NIR, SWIR1	$((RED+SWIR2) - (NIR+BLUE)) \div ((RED+SWIR2) + (NIR+BLUE))$	Toprak yüzeylerinin tespiti.	(Diek vd., 2017)
Normalize Edilmiş Fark Yerleşik Alan İndeksi (NDBI)	NIR, SWIR1	$(SWIR1- NIR) \div (SWIR1+ NIR)$	Yerleşim alanlarının tespiti.	(Zha vd., 2003)

2.3. Yöntem

Görüntülerin elde edilmesinde ve sınıflandırma işlemlerinde büyük depolama kapasitesi, yüksek bilgi işlem gücü ve sınıflandırma algoritmalarındaki başarısı nedeniyle (Gorelick vd., 2017), GEE platformu kullanılmıştır. Sonuç haritalarının sunulmasında ve tasarımında ArcGIS Pro 3.0 yazılımı kullanılmıştır. Bir UA ve Coğrafi Bilgi Teknolojileri çevrimiçi platform olan GEE, Google tarafından Aralık 2010'da piyasaya sürülmüştür. GEE, bölgesel ve küresel ölçekli çevresel izleme, haritalama ve analizler için bulut tabanlı bir mekânsal görüntü işleme platformudur (Amani vd., 2020). GEE, petabaytlarca halka açık UA görüntülerine ve web tabanlı uygulamalarıyla paylaşılan farklı coğrafi verilere erişim sağlaması; Google'ın hesaplama alt yapısını kullanan yüksek hızlı işlem kapasitesi ve JavaScript ve Python gibi yaygın programlama dillerini destekleyen programlama arabirimlerine (API) sahip olması ve makine öğrenme algoritmalarının uygulanmasını mümkün kılan bir platform olması gibi önemli avantajlara sahiptir (Rwanga ve Ndambuki 2017; Ravanelli vd., 2018; MohanRajan vd., 2020).

GEE platformu farklı makine öğrenme algoritmalarının kullanımını desteklemektedir (Kamal vd., 2019). Araştırma kapsamında Rastgele orman (RF) algoritması tercih edilmiştir. RF algoritması, en iyi tahmini elde etmek için birden fazla öğrenme ağacına sahiptir ve her ağaç bir girdi vektörünü sınıflandırmak için oy kullanır (Breiman., 2001). RF algoritması UA kapsamında örüntü tanıma ve görüntü sınıflandırma kapsamında yaygın olarak kullanılmaktadır (Stefanski vd., 2013; Karlson vd., 2015; Belgiu ve Drăgut, 2016). RF algoritması için temel parametreler ağaç sayısı ve her bölünmedeki değişken sayıdır. Araştırmada geliştirilecek ağaç sayısı 100 olarak belirlenmiş ve değişken sayısı olarak Abdollahizad vd., (2021) tarafından önerilen yöntem dikkate alınarak değişken sayısının karekökü olarak belirlenmiştir. Görüntülerin sınıflandırılmasında GEE platformu üzerinde yer alan "classifier. RandomForest" tekniği kullanılmıştır. Sınıflandırmada AÖAK sınıfları 'Su Yüzeyi', 'Orman Alanı', 'Tarım Alanı', 'Açık Yüzey' ve 'Beşerî Yüzey' olarak belirlenmiştir. Buna göre her bir sınıf için yüksek çözünürlük GEE görüntüleri üzerinden 50 eğitim poligonu oluşturulmuştur. Eğitim setinin oluşturulmasında piksel sayılarının önerilen limitin üzerinde olmasına dikkat edilmiştir (Lillesand vd., 2018).

Araştırmada sınıflandırma doğruluğunu artırmak amacıyla Tablo 2'de açıklamaları verilen NDVI, SAVI, NDWI, BSI, NDBI ve NBLI indeksleri hesaplanarak sınıflandırılan bant kombinasyonuna dâhil edilmiştir. NDVI, bölgesel ve küresel ölçeklerde vejetasyon dinamiğinin izlenmesi için yaygın olarak uygulanan en yaygın ve başarılı sonuçlar veren UA indekslerinden biridir (Colwell, 1974; Jia vd., 2014). Yakın kızılötesi (NIR) ve kırmızı bantların spektral yansımaları ile hesaplanır. NDVI değerleri tanım gereği -1 ile +1 arasında olmaktadır ve pozitif değerler artan yeşil bitki örtüsünü; negatif değerler ise bitki örtüsünden yoksun alanları göstermektedir.

NDWI, yeşil ve NIR dalga boylarını kullanarak suyun yansımalarını maksimize ederek, su yüzeylerinin bitki örtüsü ve toprak yüzeylerinden ayırt edilmesine yardımcı olmaktadır (McFeeters 1996). Tanım gereği maksimize edilmiş su özellikleri pozitif değerlere sahipken, bitki örtüsü ve toprak yüzeyleri sıfır veya negatif değerlere sahiptir.

BSI, esas olarak NDVI ve NDBI indekslerinin bir kombinasyonu şeklindedir. Çıplak toprak yüzeylerinin haritalanması ve izlenmesinde kullanılan BSI, Mavi, Kırmızı ve SWIR1 dalga boyları ile hesaplanmaktadır (Rikimaru vd., 2002; Zhao ve Chen, 2005). Ancak araştırmada NDBI indeksinin ayrıca hesaplanmış olmasından ve sınıflandırma doğruluğu açısından daha hassas sonuçlar verdiği görülen SWIR2 dalga boyları kullanılmıştır (Diek vd., 2017). Pozitif değerler açık toprak yüzeylerini gösterirken, negatif değerler su yüzeyleri ve bitki örtüsüyle kapalı alanları göstermektedir.

Araştırmada kentsel yerleşim alanlarının tespitinde kullanılan diğer bir UA indeksi NDBI'dir. SWIR ve NIR dalga boylarında hesaplanan NDBI, özellikle yol ağlarının değerlendirilmesinde önemli katkı sağlamaktadır (Zha vd., 2003). Hesaplanan NDBI değeri +1 ile -1 arasında değişmektedir. Pozitif değerler çıplak toprak yüzeylerini; negatif değerler ise su ve bitki örtüsü yüzeylerini göstermektedir.

Toprağa göre ayarlanmış bitki örtüsü indeksi olan SAVI, NDVI ile benzer ancak toprak piksellerinin etkisi aza indirger. L değerini kullanır ve bu değerinin amacı gölgelik arka plan ayarlanması ile ilgilidir. L toprağı dikkate almak için kullanılan bir faktör değeridir ve aldığı değerler birbirinden farklılık gösterir. Genellikle 0 ila 1 arası değer almaktadır. Bu değer eğer vejetasyon çok fazla yoğunluktaysa 1'e yakın değer alır ve toprağın etkisini

ortadan kaldırır (Huete, 1988). L faktörü için genelde 3 değer atanır. Bunlar 0.2, 0.5 ve 0.9 dur (Almutairivd. 2013).

NBLI, kentsel çıplak alanların belirlenmesi amacıyla kullanılmaktadır. Termal ve Kırmızı dalga boylarının kullanıldığı NBLI indeksi, inşa edilmiş araziler ile çıplak kentsel arazilerin birbirlerinden ayırt edilmesini sağlamaktadır (Li vd., 2017). Kentsel açık alanların araştırma sahasında sanayi faaliyetleri nedeniyle yaygın bulunmasından dolayı çalışmaya dahil edilmiştir.

Araştırmada sınıflandırma doğruluğu hata matrisi, kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve Kappa Katsayısı ile hesaplanmıştır. Hata matrisi, hem sınıflandırmanın doğruluğunu hem de sınıfların bireysel sınıflandırma elde etmenin etkili bir yoludur (Congalton ve Green, 2009). Çalışmada hata matrisi, değerlendirme hatalarının açık bir şekilde gösterilmesine ek olarak; genel doğruluk, üretici ve kullanıcı doğruluğu ölçümlerini hesaplamak için kullanılmıştır. Genel doğruluk değerinin hesaplanmasında aşağıdaki formül kullanılmıştır (Formül 1).

$$GD = \left(\frac{P_s}{P_t} \right) \times 100 \quad (1)$$

Formülde P_s doğru sınıflandırılmış piksel sayısını; P_t toplam piksel sayısını ifade etmektedir.


Her sınıf için kullanıcı doğruluğu, sınıftaki doğru şekilde sınıflandırılmış piksellerin toplam sınıflandırılmış piksel sayısına oranı ile belirlenirken, üretici doğruluğu ise her sınıftaki referans veriler içerisinde doğru şekilde sınıflandırılan piksellerin toplam piksel sayısına oranı ile belirlenmektedir (Congalton ve Green, 2009). Sınıflandırma doğruluğu için hesaplanan Kappa Katsayısı sıfır ile bir arasında değişen bir değere sahiptir ve k katsayısı bire eşit olması durumu mükemmel uyum anlamına gelmektedir (Jog & Dixit, 2016). K değerlerinin yorumlanmasında Monserud ve Leemans (1992) tarafından önerilen ölçek kullanılmıştır.

Bu bağlamda çalışmada 1995 ve 2022 yıllarına ait hata matrisleri oluşturulmuştur. Görüntü sınıflandırılması için üretilen poligonların, buna bağlı olarak piksellerin %70'i sınıflandırma için kullanılırken, %30'u hata matrisinin oluşturulmasında kullanılmıştır. Her sınıf detayı için araştırma sahasının tamamına yayılmış, eğitim setiyle çakışmayan, 50 eğitim örneği alt limitinin üzerinde ve birbirlerine yakın sayıda referans noktası oluşturulmuştur. Yersel doğrulama noktalarının ve referans noktalarının oluşturulmasında bölgeye ait Google Earth görüntüleri, Harita Genel Komutanlığı tarafından sunulan 1992 yılına ait sayısal topografya haritaları ve güncel ortofoto görüntüleri, İzmir Büyükşehir Belediyesi tarafından Kent Rehberi üzerinden kullanıma sunulan 2005 yılında alınan 1m çözünürlüklü uydu görüntüleri ile 2010 yılına ait ortofoto görüntüleri kullanılmıştır.

3. BULGULAR

Araştırmada daha iyi doğruluk elde etmek amacıyla bitki örtüsü, su yüzeyleri ve kentsel özellik çıkarımı UA indeksleri tercih edilmiştir. Bu kapsamda yaygın şekilde kullanılan ve ilgili bilimsel literatürde güncel indekslerden NDVI, NDWI, BSI, NDBI, SAVI ve NBLI UA indeksleri hesaplanmıştır (Şekil 3). Bu kapsamda elde edilen girdiler, 1995 ve 2022 yıllarına ait LANDSAT uydu görüntüleri ile birleştirilmiştir. Elde edilen mozaik görüntü üzerinde RF yöntemi kullanılarak Güzelhisar Havzasında AÖAK özellikleri sınıflandırılmış ve AÖAK durumlarındaki değişim değerlendirilmiştir. Bu bağlamda araştırma sahasında 'Su Yüzeyi', 'Orman Alanı', 'Tarım Alanı', 'Açık Yüzey' ve 'Beşeri Yüzey' AÖAK sınıfları analiz edilmiştir.

Buna göre araştırma sahasında 1995 yılı AÖAK durumunun mekânsal dağılımı Şekil 4'te verilmiştir. Çalışma alanında 1995 yılında en geniş alanları sırasıyla açık yüzeyler ve tarım alanları kaplamaktadır (Tablo 3). Özellikle havzanın çevresini kaplayan yüksek kesimlerde yayılış gösteren orman alanları, sahanın %12,66'lık bölümünde yer almaktadır. Bununla birlikte yaklaşık % 1,56'lık bir alan ile beşeri yüzeyler ve % 1,99'lük bir alan ile su yüzeyleri, araştırma sahasında en az yayılım gösteren arazi sınıflarıdır.



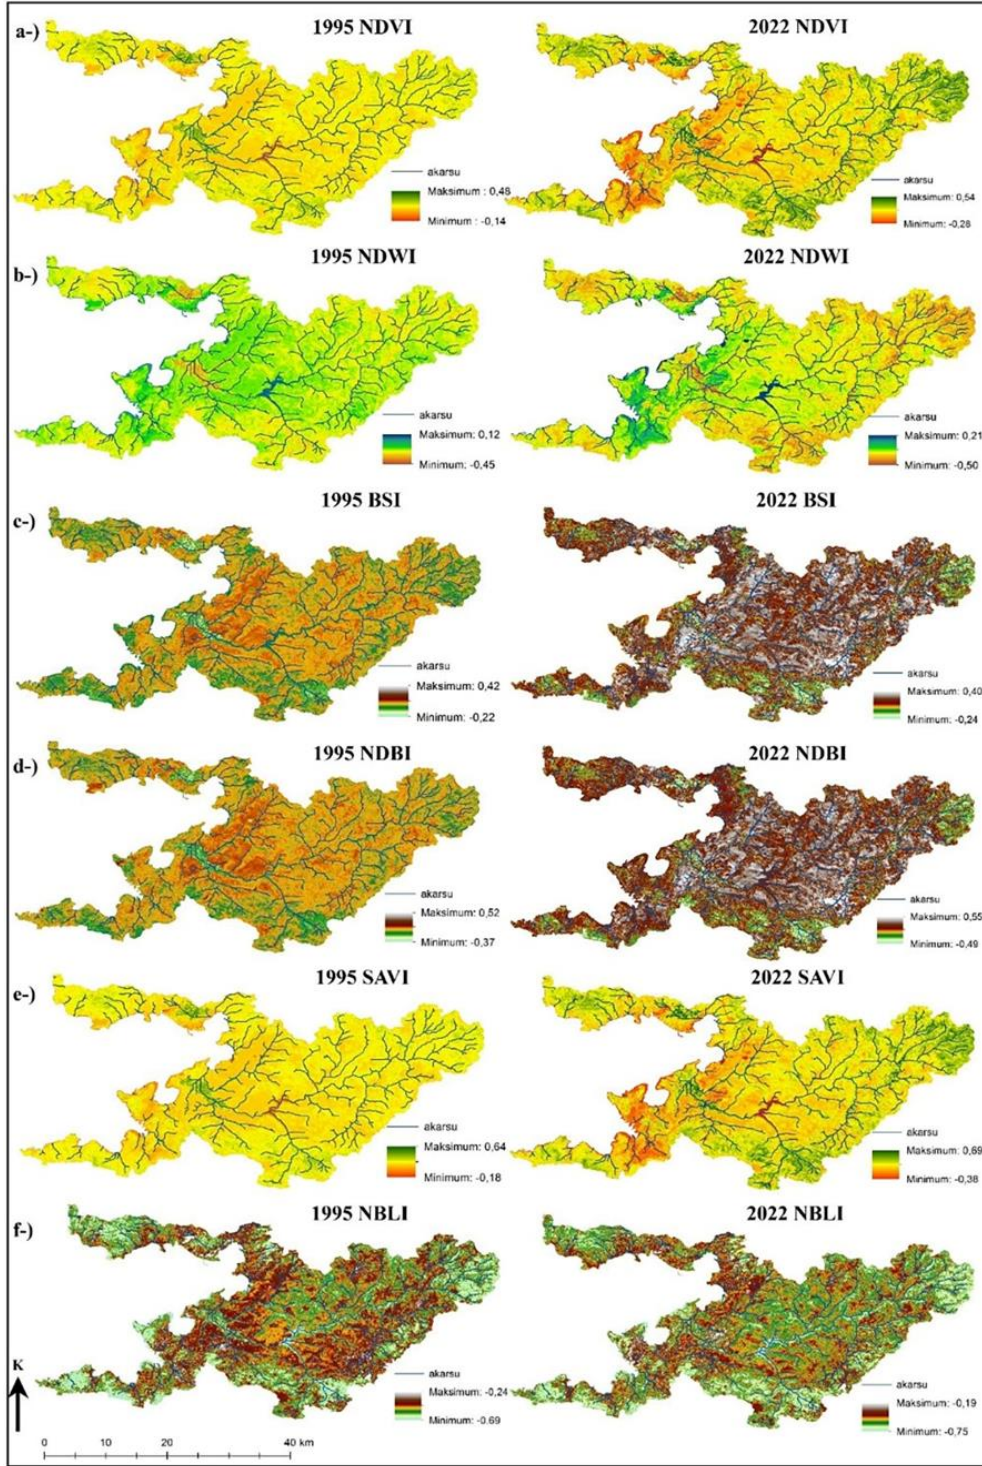
Şekil 3- Güzelhisar Havzası Arazi Örtüsü ve Arazi Kullanımı Haritası 1995
Figure 3- Land Use and Land Cover Map of Güzelhisar Basin 1995

Tablo 3- AÖAK Değerleri 1995-2022
Table 3- LULC Values 1995-2022


Sınıf	1995 - km ²	1995 - Yüzde(%)	2022 - Km ²	2022 - Yüzde(%)
Su	23.4	% 1,99	23.4	% 2,00
Orman	148.7	% 12,66	296.1	% 25,20
Tarım	273	% 23,23	178	% 15,14
Açık Alan	711.8	% 60,56	574.5	% 48,88
Beşerî Yüzey	18.3	% 1,56	103.2	% 8,78

Araştırma sahasının 2022 yılı AÖAK özellikleri incelendiğinde oldukça önemli farklılıklar olduğu dikkat çekmektedir (Şekil 5). Buna göre özellikle tarım alanlarındaki azalma ve beşerî yüzeylerdeki artış dikkat çekmektedir. 2022 yılında tarım alanları %15'lik alan kaplarken, bu oran 1995 yılında %25 civarındadır. Bununla birlikte 1995 yılında %1.5'lük bir alanda yer alan beşerî yüzeyler, 2022 yılında çalışma sahasının %9'luk bir bölümünü kaplamaktadır (Tablo 3). Diğer yandan sahada alanını genişleten diğer AÖAK özelliği ise orman alanlarıdır. 2022 yılında orman alanları sahasının %25.2'lık bir bölümünde yer almaktadır. Su yüzeyleri 1995 yılında olduğu gibi 2022 yılında da %2.00'lik oranıyla, araştırma sahasında en az yayılış gösteren AÖAK özelliğidir.

Sınıflandırma doğruluğu hata matrisi, kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve Kappa Katsayısı ile hesaplanmıştır. Hata matrisinde sütunlar doğruluğun karşılaştırıldığı referans verileri temsil ederken, satırlar uydu görüntüsünden oluşturulan sınıflandırmayı göstermektedir (Tablo 4). Buradan yola çıkarak doğru sınıflandırılan piksel sayıları kullanılarak her bir sınıfın üretici ve kullanıcı doğrulukları hesaplanmıştır. Buna göre 1995 ve 2022 yılları için hesaplanan genel doğruluk değerleri sırasıyla %95 ve %91 olarak belirlenmiştir. (Tablo 5).



Şekil 4- Sınıflandırmada Kullanılan UA İndeks Sonuçları (1995-2022)
Figure 4- Results of UA Indices Used in the Classification (1995-2022)



Şekil 5- Güzelhisar Havzası Arazi Örtüsü ve Arazi Kullanımı Haritası - 2022

Figure 5- Land Use and Land Cover Map of Güzelhisar Basin - 2022

Tablo 4- Sınıflandırma Hata Matrisi (1995-2022)

Table 4- Error Matrix of the Classification (1995-2022)

1995						Toplam	2022						Toplam
	Orman	Su	Açık Alan	Tarım	Beşerî Alan			Orman	Su	Açık Alan	Tarım	Beşerî Alan	
Orman	122	0	2	4	0	128	Orman	77	0	0	2	0	79
Su	0	54	0	0	0	54	Su	2	84	0	1	0	87
Açık	0	0	542	6	4	552	Açık	0	0	80	5	6	91
Tarım	2	0	9	286	3	300	Tarım	1	0	10	74	0	85
Beşerî	0	0	10	8	43	61	Beşerî	0	0	7	4	74	85
Toplam	124	54	563	304	50	1095	Toplam	80	84	97	86	80	427

Tablo 5- ÜD: Üretici Doğruluğu, KD: Kullanıcı Doğruluğu (1995-2022)

Table 5- ÜD: Producer's Accuracy, KD: User's Accuracy (1995-2022)

Sınıf	ÜD1995	KD1995	ÜD2022	KD2022
Su Yüzeyleri	%100	%100	%94,1	%97,5
Orman Alanları	%95,3	%98,3	%97,5	%96,2
Tarım Alanları	%95,3	%94	%82,5	%92,2
Açık Yüzeyler	%98,1	%96,2	%86,7	%85,5
Beşerî Alanlar	%70,4	%86	%91,8	%83,3
Genel Doğruluk: 0.95		Kappa Katsayısı: 0.93		Genel Doğruluk: 0.91
				Kappa Katsayısı: 0.88

Sınıflandırma sonuçlarının istatistiksel olarak uygunluğu Kappa Katsayısı ile hesaplanmıştır. Buna göre elde edilen Kappa Katsayısı (k) ne kadar az ise sonuçların rastlantısallığı; (k) katsayısı ne kadar fazla ise sonuçların istatistiksel uyumu o kadar artmaktadır (Jog & Dixit, 2016). Araştırmada 1995 ve 2022 yılları Kappa Katsayıları istatistiksel olarak kabul edilebilir sınırın (Monserud & Leemans, 1992) üzerinde bulunmuştur (Tablo 6).


Tablo 6- Kappa Sayısı Değer İfadeleri (Monserud & Leemans, 1992)
Table 6- Kappa Coefficient Expressions (Monserud & Leemans, 1992)

Kappa Sayısı	İfadesi	Veri Doğruluğu
0-0.20	Yok	%0-4
0.21-0.39	Çok az	%4-15
0.40-0.59	Zayıf	%15-35
0.60-0.79	Orta	%35-63
0.80-0.90	Güçlü	%64-81
0.90 ve üstü	Çok güçlü	%82-100

AÖAK özelliklerinde zaman içerisinde değişimin yaşandığı alanların tespit edilmesi ve değişimin boyutlarının hesaplanması, mevcut ekolojik baskının durumunu ortaya koymada önemli bilgiler vermektedir. Bununla birlikte geçmişten günümüze AÖAK özelliklerindeki değişimin hızı ve yönü, mekânsal planlama süreçlerine önemli katkılar sağlamaktadır. Bu bağlamda araştırma sahasında 1995-2022 yılları arasında AÖAK özelliklerinde meydana gelen değişimin hızı ve yönü bilgileri hesaplanmıştır (Tablo 7). Buna göre araştırma sahasında yüksek değişimlerden biri ‘Tarım alanlarından Beşerî Yüzeyler yönünde olduğu tespit edilmiştir. Öyle ki bu hızlı değişim sonucunda 1995 yılında 273 km² olan tarım alanlarının genişliği, 2022 yılında 178 km²’ye gerilemiştir (Şekil 6). Diğer bir ifadeyle 1995 yılındaki mevcut tarım alanlarının yaklaşık %40’ı günümüzde artık bulunmamaktadır ve bu alanlar büyük oranda kentsel alan olarak kullanılmaktadır. Araştırma sahasında dikkat çeken bir diğer değişim beklendiği gibi beşerî yüzeyler üzerinde olmuştur. Söz konusu 1995-2022 yılları arasında en fazla genişleyen AÖAK sınıfı olmuştur (Şekil 6).

Tablo 7- AÖAK Değişim Yönü (1995-2022)
Table 7- Change Detection of the LULC Classification (1995-2022)

Değişimin Yönü (%)	1995-2022 %	1995-2022 km ²	Değişimin Yönü (%)	1995-2022 %	1995-2022 km ²
Hep Orman Alanı Olan	86,52	92,2	Tarım Alanıyken Açık Yüzey Olan	24,83	53,5
Orman Alanıyken Su Yüzeyi Olan	0,06	0,06	Tarım Alanıyken Beşerî Alan Olan	7,61	16,4
Orman Alanıyken Tarım Alanı Olan	4,79	5,1	Hep Açık Yüzey Olan	69,60	388
Orman Alanıyken Açık Yüzey Olan	7,41	7,9	Açık Yüzeyken Orman Alanı Olan	9,33	52
Orman Alanıyken Beşerî Alan Olan	1,22	1,3	Açık Yüzeyken Su Yüzeyi Olan	0,09	0,5
Hep Su Yüzeyi Olan	88,15	16	Açık Yüzeyken Tarım Alanı Olan	11,84	66
Su Yüzeyiyken Orman Alanı Olan	2,20	0,4	Açık Yüzeyken Kentsel Alan Olan	9,15	51
Su Yüzeyiyken Tarım Alanı Olan	0,28	0,05	Hep Beşerî Yüzey Olan	72,8	9,5
Su Yüzeyiyken Açık Yüzey Olan	0,55	0,1	Beşerî Yüzeyken Orman Alanı Olan	3,83	0,5
Su Yüzeyiyken Beşerî Alan Olan	8,82	1,6	Beşerî Yüzeyken Su Yüzeyi Olan	3,07	0,4
Hep Tarım Alanı Olan	31,55	68	Beşerî Yüzeyken Tarım Alanı Olan	12,26	1,6
Tarım Alanıyken Orman Alanı Olan	35,73	77	Beşerî Yüzeyken Açık Yüzey Olan	8,05	1,05
Tarım Alanıyken Su Yüzeyi Olan	0,28	0,6			



Şekil 6- 1995-2022 Sınıfların Alansal Karşılaştırması

Figure 6- 1995-2022 Comparison of Area of the Classes

4. SONUÇ

Araştırma kapsamında Güzelhisar Havzasında sanayi faaliyetlerine bağlı olarak bölgede artan insan baskısının AÖAK durumu üzerindeki etkisini ortaya koymak amaçlanmıştır. Bu bağlamda sahanın 1995 – 2022 yılı AÖAK özellikleri, çok bantlı uydu görüntüleri üzerinden RF makine öğrenmesi algoritması ile sınıflandırılmıştır. Sınıflandırmada ayrıca çeşitli UA indeksleri doğruluğu artırmak amacıyla yardımcı veri olarak kullanılmıştır. Araştırma sonuçları arazi kullanımı planlaması ve kentsel genişlemenin tahmin edilmesi amacıyla kullanılabilir niteliktedir (Kamal vd., 2019; Amani vd., 2020).

Araştırma sahasında beşerî yüzeylerde önemli miktarda artış meydana gelirken, tarım alanlarında ve açık yüzeylerde azalma olduğu tespit edilmiştir. Beşerî yüzeylerdeki artış miktarı dikkate alındığında bölgede sanayi faaliyetlerine bağlı istihdam potansiyelinin kentleşme üzerindeki etkisi olarak yorumlanabilir. Nitekim bölgede gerçekleştirilen çalışmalar neticesinde sahanın zayıf yönleri olarak gösterilen noktalar bu yöndedir (Bağmancı, 2010, Eroğlu ve Bozyiğit, 2013). Bu durum ayrıca bölgenin uzun yıllar artan nüfusuna paralel arazi kullanım özelliklerinde meydana gelen değişimin göstergesi özelliğindedir.

Araştırma sahasında yanlış arazi kullanımı faaliyetleri önemli bir çevre sorunudur (Eroğlu, 2015). Elde edilen bulgularda beşerî yüzeylerde meydana gelen artışın önemli bir miktarının 1995 yılında tarım alanı ve açık yüzey olan sahalardan meydana geldiğini tespit etmiştir. Bu bağlamda bölgede yanlış arazi kullanımına bağlı sorunların olduğu görülmektedir. Ayrıca tarım alanlarında ve açık yüzeylerde meydana gelen azalma tarım ve hayvancılık faaliyetleri ile de ilişkili olduğu düşünülmektedir. Nitekim araştırma sahasında tarım ve hayvancılık faaliyetlerinin giderek önemsizleştiği gözlenmektedir (Bağmancı, 2010). Araştırmada ayrıca çalışma sahasında 1995-2022 yılları arasında orman alanlarında artış meydana geldiği tespit edilmiştir. Bölgede gerçekleştirilen ağaçlandırma faaliyetlerinin söz konusu değişimi etkileyecek boyutta olmadığı görülmektedir (Öner, 2006). Ormanlık alanlara dönüşen sahaların genelde açık yüzeylerden meydana gelmektedir ancak gerçekte bu durumun orman sınıfının tarım alanları ile karışmasından dolayıdır. Bununla birlikte tarım alanlarından ormanlık alanlara dönüşen alan miktarındaki yükseklik de bu nedenledir. RF algoritmasının söz konusu sınıfların ayırt edilmesinde başarılı sonuçlar vermediği görülmektedir. Nitekim bu sorunların bulut maskeleye algoritmalarından veya nem, pus, sis gibi atmosferik durumlardan kaynaklanabilmektedir (Hossein Shafizadeh, 2021).

Sonuç olarak araştırma kapsamında GEE platformunun yetenekleri, makine öğrenmesine dayalı sınıflandırma algoritması, sınıflandırma süreçleri ve elde edilen bulguların değerlendirilmesine kadar olan tüm süreç performansları değerlendirilmiştir. Bu bağlamda GEE platformu ile üst ölçekli mekânsal planlama süreçlerinde, soyutlama düzeyi yüksek, ilke düzeyinde AÖAK özelliklerinin haritalanmasında ve analizinde önemli katkılar sunabilecek özelliklere sahiptir. Bu açıdan çalışmanın tüm sonuçları, gelecekte yapılacak

çalışmaların geliştirilmesi, ayrıca Uzaktan Algılama ve Coğrafi Bilgi Sistemleri araştırmalarında açık veri kaynaklarının ve bulut tabanlı platformların yaygınlaşması açısından önem arz etmektedir.

Cıkar Çatışması / Conflict of Interest	Yazarlar çıkar çatışması bildirmemiştir. The authors declared no conflict of interest
Finansal Destek / funding conditions	Yazarlar bu çalışma için finansal destek almadıklarını beyan etmiştir. The authors declared that this study has received no financial support
Yazar Katkıları/Author Contributions	Yazarlar/Authors
Çalışmanın içeriği ve tasarımı/Conception/Design of Study	Ş. Danacıoğlu
Metodoloji/Methodology	Ş. Danacıoğlu
Veri toplama-oluşturma-iyileştirme/Data Curation	H. C. Öngül
Analiz/Analysis and interpretation of data	Ş. Danacıoğlu – H. C. Öngül
Görselleştirme/ Visualization	H. C. Öngül
Yazı taslağı/Writing - Original Draft	Ş. Danacıoğlu
Yazma - İnceleme ve Düzenleme/Writing - Review & Editing	Ş. Danacıoğlu
Proje yönetimi/Project administration	

REFERANSLAR

- Abdollahizad, S., Balafar, M. A., Feizizadeh, B., Babazadeh Sangar, A., & Samadzamini, K. (2021). Using hybrid artificial intelligence approach based on a Neuro-Fuzzy System and evolutionary algorithms for modeling landslide susceptibility in East Azerbaijan province, Iran. *Earth Science Informatics*. doi: <https://doi.org/10.1007/s12145-021-00644-z>
- Aliğa Organize Sanayi Bölgesi Yönetim Kurulu (2022), Kurumsal bilgi, Ekim 30, 2022 tarihinde ALOSBI: <https://www.alosbi.org.tr/kurumsal> adresinden alınmıştır.
- Almutairi, B., El, A., Belaid, M. A., & Musa, N. (2013). Comparative study of SAVI and NDVI vegetation indices in sulaiabiya area (Kuwait) using worldview satellite imagery. *Int. J. Geosci. Geomatics*, 1, 50-53.
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A. and Mirmazloumi, S. M. (2020). Google Earth Engine cloud computing platform for remote sensing big data applications: A comprehensive review," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 13, pp. 5326–5350, doi: <https://doi.org/10.1109/JSTARS.2020.3021052>
- Arabameri, A., Roy, J., Saha, S., Blaschke, T., Ghorbanzadeh, O., & Bui, D.T. (2019). Application of probabilistic and machine learning models for groundwater potentiality mapping in damghan sedimentary plain, Iran. *Remote Sensing* 11 (24): 3015. doi: <https://doi.org/10.3390/rs11243015>
- Atumane, A., Cabral, P. (2021). Integration of ecosystem services into land use planning in Mozambique. *Ecosystems and People* 17:1, pages 165-177. doi: <https://doi.org/10.1080/26395916.2021.1903081>
- Balchin, P. N., Isaac, D. & Chen, J. (2000). *Urban Economics: a global perspective*, Palgrave, New York.
- Bayırhan, İ., & Nas, S. (2018). Güzelhisar Deresi'nin Aliğa Organize Sanayi Bölgesi İçin Suyolu Olarak Tasarımı. *Teknik Dergi*, 29(1), 8199-8224, doi: <https://doi.org/10.18400/tekderg.346896>
- Bağmancı, M. F. (2010). Aliğa İlçe Merkezinin Beşerî Ve Ekonomik Coğrafyası. Kahramanmaraş Sütçü İmam Üniversitesi sosyal Bilimler Enstitüsü coğrafya Ana Bilim Dalı. Basılmamış Yüksek Lisans Tezi.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 114, Pages 24-31, <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Belward, A.S. & Sköien, J.O. (2015). Who launched what, when and why; trends in global land cover observation capacity from civilian earth observation satellites *ISPRS J. Photogramm. Remote Sens.*, 103, pp. 115-128, doi: <https://doi.org/10.1016/j.isprsjprs.2014.03.009>
- Bozdağ, A., Dokuz, Y., & Gökçek, Ö.B. (2020). Spatial prediction of pm10 concentration using machine learning algorithms in Ankara, Turkey. *Environmental Pollution (Barking, Essex: 1987)* 263: 114635. doi: <https://doi.org/10.1016/j.envpol.2020.114635>
- Breiman L. (2001). Random forests. *Machine Learn.* 45(1):5–32.
- Cihlar, J. (2000). Land cover mapping of large areas from satellites: status and research priorities. *Int. J. Remote Sens.* 21, 1093–1114, doi: <https://doi.org/10.1080/014311600210092>

- Colwell, J. E. (1974). Vegetation canopy reflectance. *Remote Sensing of Environment*, 3, 175–183.
- Congalton, R.G. and Green, K., (2009). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, 2nd ed. (Boca Raton, FL: CRC Press), doi: <https://doi.org/10.1201/9780429052729>
- Cracknell, M. J., & Reading, A.M. (2014). Geological mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Computers & Geosciences* 63: 22–33. doi: <https://doi.org/10.1016/j.cageo.2013.10.008>
- Danacıoğlu, Ş. (2019). Arazi kullanımı/Arazi örtüsü ve uzaktan algılama. D.D. Yavaşlı ve M.K. Ölgün (Ed.), *Coğrafyada Uzaktan Algılama içinde* (s. 161-198). İstanbul: Kriter Yayınevi.
- Diek, S., Fornallaz, F., Schaepman, M.E., de Jong, R. (2017). Barest Pixel Composite for agricultural areas using LANDSAT time series. *Remote Sensing*, 9, 1245, doi: <https://doi.org/10.3390/rs9121245>
- Eroğlu, İ., & Bozyiğit, R. (2011). Güzelhisar Çayı Havzasında yapısal unsurların jeomorfolojik birimlere etkileri. *Selçuk Üniversitesi Ahmet Keleşoğlu Eğitim Fakültesi Dergisi*, 32, 169-190.
- Eroğlu, İ. ve Bozyiğit, R. (2013), Aliğa İlçesinde Arazi Kullanımına Etki Eden Doğal ve Beşerî Faktörler. *Marmara Coğrafya Dergisi*, 27, 353-400, İstanbul
- Eroğlu, İ. (2015). Aliğa İlçesindeki (İzmir) Çevre Sorunlarının Coğrafi Açından Değerlendirilmesi. *Coğrafyacılar Derneği Uluslararası Kongresi*, 21-23 Mayıs Başkent Öğretmenevi, Ankara, Türkiye.
- Gashaw, T., Tulu, T., Argaw, M., Worqlul, A.W. (2018). Modeling the hydrological impacts of land use/land cover changes in the Andassa watershed, blue Nile basin, *Ethiopia. Sci. Total Environ.*, 619–620, pp. 1394–1408, doi: <https://doi.org/10.1016/j.scitotenv.2017.11.191>
- Ge, G., Shi, Z., Zhu, Y., Yang, X., Hao, Y., (2020). Land use/cover classification in an arid desert-oasis mosaic landscape of China using remote sensed imagery: Performance assessment of four machine learning algorithms. *Global Ecology and Conservation*, 22, e00971, doi: <https://doi.org/10.1016/j.gecco.2020.e00971>
- Geenhuizen, V. M. & Nijkamp, P. (1995). 'Urbanization, industrial dynamics, and spatial development: a company life history approach', in *Urban agglomeration and economic growth*, ed. Giersch, H., Springer, New York, pp. 39-40, doi: 10.1007/978-3-642-79397-4_2.
- Giri, C.P. (2012). *Remote Sensing of Land Use and Land Cover: Principles and Applications*; CRC Press, Taylor and Francis Group: Boca Raton, FL, USA.
- Gorelick N, Hancher M, Dixon M, Ilyushchenko S, Thau D, Moore R (2017) Google Earth Engine: planetary-scale geospatial analysis for everyone. *Remote Sens Environ* 202:18–27, doi: <https://doi.org/10.1016/j.rse.2017.06.031>
- Hayter, R. (1997). *The dynamics of industrial location: the factory, the firm and the production system*, John Wiley & Sons, Sussex.
- Hejar, S., Jarihani, B., Piralilou, S.T., Chittleborough, D., Avand, M. & Ghorbanzadeh, O. (2019). A Semi-Automated object-based gully networks detection using different machine learning models: A Case study of Bowen catchment, Queensland, Australia. *Sensors* 19 (22): 4893. doi: <https://doi.org/10.3390/s19224893>
- Hossein Shafizadeh-Moghadam, Morteza Khazaei, Seyed Kazem Alavipanah & Qihao Weng (2021) Google Earth Engine for large-scale land use and land cover mapping: an object-based classification approach using spectral, textural and topographical factors, *GIScience & Remote Sensing*, 58:6, 914-928, doi: 10.1080/15481603.2021.1947623
- Hu Y., Dong Y., Batunacun, Y. (2018). An automatic approach for land-change detection and land updates based on integrated NDVI timing analysis and the CVAPS method with GEE support. *ISPRS J Photogramm Remote Sens.* 146:347–359, doi: <https://doi.org/10.1016/j.isprsjprs.2018.10.008>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309, doi: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Javed, A., Cheng, Q., Peng, H., Altan, O., Li, Y., Ara, I., Huq, E., Ali, Y., Saleem, N. (2021). Review of spectral indices for urban remote sensing. *Photogramm. Eng. Remote Sens.*, 87, 513–524, doi: <https://doi.org/10.14358/PERS.87.7.513>

- Jia, K., Liang, S., Wei, X., Yao, Y., Su, Y., Jiang, B., & Wang, X. (2014). Land cover classification of LANDSAT data with phenological features extracted from Time Series MODIS NDVI Data. *Remote Sensing*, 6(11), 11518–11532. <https://doi.org/10.3390/rs61111518>
- Jog, S., & Dixit, M., (2016). Supervised classification of satellite images. *2016 Conference on Advances in Signal Processing (CASP), IEEE*, 93–98, doi: <https://doi.org/10.1109/CASP.2016.7746144>
- Kamal, M., Jamaluddin, I., Parella A., & Farda N.M. (2019). Comparison of Google Earth Engine (GEE)-based Machine Learning Classifiers for Mangrove Mapping. *The 40th Asian Conference on Remote Sensing (ACRS 2019) October 14-18, 2019 / Daejeon Convention Center (DCC), Daejeon, Korea*
- Karlson, M., Ostwald, M., Reese, H., Sanou, J., Tankoano, B., Mattsson, E. (2015). Mapping tree canopy cover and aboveground biomass in Sudano-Sahelian woodlands using LANDSAT 8 and random forest. *Remote Sensing*, 7, p. 10017, doi: <https://doi.org/10.3390/rs70810017>
- Khan, N., Sachindra, D. A., Shahid, S., Ahmed, K., Shiru, S. M. & Nawaz, N. (2020). Prediction of droughts over Pakistan using machine learning algorithms. *Advances in Water Resources* 139: 103562. doi: <https://doi.org/10.1016/j.advwatres.2020.103562>
- Kotsiantis S. B. (2007). *Supervised machine learning: a review of classification techniques*. *Informatica*,31:249–268.
- Lambin, E.F. (1999). Monitoring forest degradation in tropical regions by remote sensing: some methodological issues. *Global Ecology and Biogeography*, 8: 191-198. <https://doi.org/10.1046/j.1365-2699.1999.00123.x>
- Lary, D.J., Alavi, A. H., Gandomi, A.H., Walker, A.L. (2016). Machine learning in geosciences and remote sensing, *Geoscience Frontiers*, 7 (1), 3-10. doi: <https://doi.org/10.1016/j.gsf.2015.07.003>
- Li H, Wang C, Zhong C, Su A, Xiong C, Wang J & Liu J. (2017). Mapping urban bare land automatically from LANDSAT imagery with a simple index. *Remote Sensing*. 9(3):249. doi: <https://doi.org/10.3390/rs9030249>
- Li, M, Zang, S, Zhang, B, Li, S, Wu, C. (2014) A review of remote sensing image classification techniques: the role of spatio-contextual information. *European Journal of Remote Sensing* 47(1):389–411. <https://doi.org/10.5721/EuJRS20144723>
- Lillesand, T.M., Kiefer, R.W. , ve Chipman, J.W. (2018). *Uzaktan Algılama ve Görüntü Yorumalama* (K.Ş. Kavak, Çev.), Palme Yayınevi (Orişinal çalışma basım tarihi 2015).
- Liu. X., Zhu, X., Zhang, O., Yang, T., Pan, Y., & Sun, P. (2020). A Remote sensing and artificial neural network-based integrated agricultural drought index: Index development and applications. *Catena* 186: 104394. doi: <https://doi.org/10.1016/j.catena.2019.104394>
- Loveland, T., Sohl, T., Stehman, S., Gallant, A., Sayler, K., Napton, D. (2002). A strategy for estimating the rates of recent United States land cover changes. *Photogramm. Eng. Remote Sens.* 68, 1091–1099.
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. Doi: <https://doi.org/10.1080/01431161.2018.1433343>
- McFeeters, S. K. (1996). The use of normalized difference water index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, 17: 1425–1432. Doi: <https://doi.org/10.1080/01431169608948714>
- MohanRajan, S.N., Loganathan, A. & Manoharan, P. (2020). Survey on Land Use/Land Cover (LU/LC) change analysis in remote sensing and GIS environment: Techniques and Challenges. *Environ Sci Pollut Res* 27, 29900–29926. <https://doi.org/10.1007/s11356-020-09091-7>
- Monserud, R. A., Leemans, R., (1992). Comparing global vegetation maps with the Kappa statistic. *Ecological modelling*, 62(4), 275–293, doi: [https://doi.org/10.1016/0304-3800\(92\)90003-W](https://doi.org/10.1016/0304-3800(92)90003-W)
- Öner, N. (2006). Aliağa-Kemalpaşa (İzmir) Yöresinde Yapılan Kızılçam ve Fıstıkçamı Ağaçlandırmalarının Başarısı. *Abant İzzet Baysal Üniversitesi Ormancılık Dergisi*2 (1), 68–78
- Pan, X., Wang, Z., Gao, Y., Dang, X., Han, Y. (2022). Detailed and automated classification of land use/land cover using machine learning algorithms in Google Earth Engine, *Geocarto International*, 37:18, 5415-5432, doi: <https://doi.org/10.1080/10106049.2021.1917005>

- Prakash, N., Manconi, A. & Loew, S. (2020). Mapping Landslides on EO Data: Performance of Deep Learning Models vs. traditional Machine Learning Models. *Remote Sensing* 12 (3): 346. doi: <https://doi.org/10.3390/rs12030346>
- Rai, S., Sharma, E., & Sundriyal, R. (1994). Conservation in the Sikkim Himalaya: Traditional knowledge and land-use of the mamlay Watershed. *Environmental Conservation*, 21(1), 30-34. doi: <https://doi.org/10.1017/S0376892900024048>
- Ravanelli, R., A. Nascetti, R. V. Cirigliano, C. Di Rico, P. Monti, and Crespi, M. (2018). Monitoring Urban Heat Island through Google Earth Engine: Potentialities and Difficulties in Different Cities of the United States. The International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences* XLII-3: 1467–1472. doi: <https://doi.org/10.5194/isprs-archives-XLII-3-1467-2018>
- Rikimaru, A., Roy, P.S. & Miyatake, S. (2002). Tropical forest cover density mapping. *Trop. Ecol.*, 43, 39–47.
- Rojan, J., Chen, D. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Prog. Plan.*, 61, 301–325.
- Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy assessment of land use/land cover classification using remote sensing and GIS. *International Journal of Geosciences* 08 (04): 611–622. doi: <https://doi.org/10.4236/ijg.2017.84033>
- Salazar, A., Baldi, G., Hirota, M., Syktus, J., McAlpine, C., (2015). Land use and land cover change impacts on the regional climate of non-Amazonian South America: a review. *Glob. Planet. Change* 128, 103–119, doi: <https://doi.org/10.1016/j.gloplacha.2015.02.009>
- Simmons, I. G. (2008). *Global environmental history: 10,000 BC to AD 2000*. Edinburgh University Press.
- Stefanski, J., Mack, B., Waske, B. (2013). Optimization of object-based image analysis with random forests for land cover mapping. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 6, pp. 2492-2504, doi: <https://doi.org/10.1109/JSTARS.2013.2253089>
- Taghizadeh-Mehrjardi, R., Toomanian, N., Shamsirband, S., Mosavi, A., Behrens, T., Schmidt, K., and Scholten, T.: Predicting and mapping of soil salinity using machine learning algorithms in central arid regions of Iran, *EGU General Assembly 2020*, Online, 4–8 May 2020, EGU2020-18516, <https://doi.org/10.5194/egusphere-egu2020-18516> , 2020
- Tanrıvermiş H, Mülayim ZG (1999). Sanayinin Neden Olduğu Çevre Kirliliğinin Tarıma Verdiği Zararların Değerinin Biçilmesi: Samsun Gübre (TÜGSAS) ve Karadeniz Bakır (KBI) Sanayileri Örneği. *Tr. J. of Agriculture and Forestry* 23: 337- 345.
- Turner, B, L., Lambin, E, F., Reenberg, A. (2007). The emergence of land change science for global environmental change and sustainability. *Proc Natl Acad Sci USA* 104, 20666–20671, doi: <https://doi.org/10.1073/pnas.0704119104>
- Viana, C. M., Oliveira, S., Oliveira, S. C. & Rocha, J. (2019). 29—Land use/land cover change detection and urban sprawl analysis, in *Spatial Modeling in GIS and R for Earth and Environmental Sciences*, H. R. Pourghasemi and C. Gokceoglu, Eds. Amsterdam, *The Netherlands: Elsevier*, pp. 621–651, doi: <https://doi.org/10.1016/B978-0-12-815226-3.00029-6>
- Xie S, Liu L, Zhang X, Yang J, Chen X, Gao Y. (2019). Automatic land-cover mapping using LANDSAT time-series data based on Google Earth Engine. *Remote Sens.* 11(24):3023, doi: <https://doi.org/10.3390/rs11243023>
- Yang C, He X, Yan F, Yu L, Bu K, Yang J, Chang L, Zhang S. (2017). Mapping the influence of land use/land cover changes on the urban heat island effect—a case study of Changchun, China. *Sustainability* 9(2):312. <https://doi.org/10.3390/su9020312>
- 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, doi: <https://doi.org/10.1080/01431160304987>
- Zhao, H. & Chen, X. (2005). Use of normalized difference bareness index in quickly mapping bare areas from TM/ETM+. In *Proceedings of the 2005 IEEE International Geoscience and Remote Sensing Symposium*, Seoul, Korea, 29 July 2005; pp. 1666–1668.