



Arazi kullanımı ve arazi örtüsü belirleme çalışmalarında nesne tabanlı ve piksel tabanlı sınıflandırma yöntemlerinin karşılaştırılması: Yedigöze Baraj Gölü ve çevresi örneği

Comparison of object based and pixel based classification methods in land use and land cover determination studies: The case of Yedigoze Reservoir Area

Sevim Yasemin Çiçekli^{1,*} 

¹ Çukurova Üniversitesi, Jeoloji Mühendisliği Bölümü, 01330, Adana Türkiye

Öz

Uydu tekniklerinin gelişmesiyle birlikte, AKAÖ (Arazi Kullanımı ve Arazi Örtüsü) belirlemek amacıyla uydu görüntüleri ve görüntü sınıflandırma algoritmaları daha sık kullanılmaktadır. Bu çalışmanın temel amacı Yedigöze Baraj Gölü çevresinde nesne tabanlı ve piksel tabanlı görüntü sınıflandırma yöntemleri ile sınıflama işlemini gerçekleştirmek ve sınıflama tekniklerinin genel doğruluklarını karşılaştırmaktır. Bu çalışmada Yedigöze Baraj Gölü'nün 24 Haziran 2023 tarihinde alınan Sentinel-2B uydu görüntüsü kullanılmıştır. İlk olarak görüntü, DVM (Destek Vektör Makineleri), YSA (Yapay Sinir Ağları) ve MOS (Maksimum Olabilirlik Sınıflandırması) yöntemiyle piksel tabanlı sınıflandırma yöntemiyle sınıflandırılmıştır. Daha sonra görüntü, KEYK (K-En Yakın Komşuluk) yöntemiyle nesne tabanlı sınıflandırma yöntemiyle sınıflandırılmıştır. Bu algoritmalar kullanılarak su alanı, tarım alanı, orman alanı ve yerleşim alanı olmak üzere dört sınıf belirlenmiştir. Genel doğruluklar DVM yöntemi için %92.92, YSA yöntemi için %92.42, MOS yöntemi için %86.71 ve KEYK yöntemi için %93.18 olarak hesaplanmıştır. Çalışma sonucunda, olarak, tüm yöntemlerin yüksek doğruluk sağladığı ve nesne tabanlı KEYK yönteminin diğer sınıflandırma yöntemlerine göre daha yüksek doğruluk sağladığı tespit edilmiştir.

Anahtar kelimeler: Destek vektör makineleri, Yapay sinir ağları, Maksimum olabilirlik sınıflandırması, K-en yakın komşuluk, Uzaktan algılama

1 Giriş

Uzaktan algılama teknolojisi AKAÖ haritaları oluşturmak, arazi kullanımı ve arazi örtüsü değişikliklerini tespit etmek, sulak alan yönetimi, ekolojik çalışmalar ve doğal afetlerin izlenmesi için yıllar içinde yaygın olarak kullanılmıştır. Nüfus artışı ile birlikte sulak alanların gözlemlenmesi ve su yönetimi büyük önem kazanmıştır. Su alanları ve çevresinde, arazi kullanımı ve arazi örtüsü haritaları, gözlem ve takip açısından sınıflandırma algoritmaları kullanılarak oluşturulabilir ve izlenebilir. Görüntü sınıflandırma temel olarak piksel tabanlı ve nesne tabanlı olmak üzere iki kategoriye ayrılmaktadır. Uzaktan algılama çalışmalarında, piksel tabanlı sınıflandırma tekniği sıklıkla kullanılırken, piksel tabanlı sınıflandırma yöntemine

Abstract

With the development of satellite techniques, satellite images and image classification algorithms are used more frequently to determine LULC (Land Use and Land Cover). The main purpose of this study is to perform the classification process with object-based and pixel-based image classification methods in the Yedigöze Reservoir area and to compare the general accuracies of the classification techniques. In this study, Sentinel -2B satellite image of Yedigöze Reservoir taken on June 24, 2023 was used. First, the image was classified by pixel-based classification using SVM (Support Vector Machines), ANN (Artificial Neural Networks) and MLC (Maximum Likelihood Classification) method. Then, the image was classified by object-based classification using the KNN (K-Nearest Neighbor) method. Using these algorithms, four classes were determined: water area, agricultural area, forest area and residential area. Overall accuracies were calculated as 92.92% for the SVM method, 92.42% for the ANN method, 86.71% for the MLC method and 93.18% for the KNN method. As a result of the study, it has been determined that all methods provide high accuracy and the object-based KNN method provides higher accuracy than other classification methods.

Keywords: Support vector machines, Artificial neural networks, Maximum likelihood classification, K-nearest neighbor, Remote sensing

alternatif olarak nesne tabanlı sınıflama yöntemi geliştirilmiş ve kullanılmıştır.

Literatür incelendiğinde nesne tabanlı sınıflandırma tekniği ile piksel tabanlı görüntü sınıflandırmanın doğruluklarını karşılaştırmak amacıyla yapılmış birçok çalışma bulunmaktadır. Gholoobi, Tayyebi, Taleyi ve Tayyebi [1] tarafından dağlık bölgelerde arazi kullanımı /arazi örtüsünü belirlemek için yapılan çalışmada piksel tabanlı ve nesne tabanlı sınıflandırma tekniklerini kullanılarak, kullanılan nesne tabanlı sınıflandırma yönteminin, piksel tabanlı sınıflama yönteminden daha doğru sonuçlar verdiği tespit edilmiştir. Nesne tabanlı sınıflandırma yönteminin %87.38 genel doğruluk, piksel tabanlı sınıflama yöntemi %74.38 genel doğruluk

* Sorumlu yazar / Corresponding author, e-posta / e-mail: s.y.cicekli@gmail.com (S. Y. Çiçekli)

Geliş / Received: 26.04.2024 Kabul / Accepted: 29.08.2024 Yayınlanma / Published: 15.10.2024

doi: 10.28948/ngumuh.1472869

sağlamıştır. Kalkan ve Maktav [2] tarafından yapılan çalışmada piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yöntemlerini karşılaştırılmış ve nesne tabanlı sınıflandırma tekniğinin, piksel tabanlı sınıflama tekniğine göre daha yüksek doğruluğa sahip olduğunu tespit edilmiştir. Nesne tabanlı sınıflandırma tekniği %98.39 genel doğruluk, piksel tabanlı sınıflama tekniği %92.91 genel doğruluk sağlamıştır. Zhang vd. [3] tarafından yapılan çalışmada Heine Nehri havzasında Spot-5 görüntülerini kullanarak nesne tabanlı sınıflandırma gerçekleştirilmiştir. Nesne tabanlı sınıflandırmanın %94 genel doğruluk ile sonuç verdiğini gözlemlenmiştir. Al Fugara vd. [4] tarafından yapılan çalışmada Landsat-7 görüntülerini kullanarak Malezya'nın Klong vadisinde piksel tabanlı ve nesne tabanlı sınıflandırma gerçekleştirilmiştir. Çalışma sonucunda nesne tabanlı sınıflandırma yönteminin daha yüksek doğruluk sağladığı tespit edilmiştir. Nesne tabanlı sınıflandırma tekniği %89.78 genel doğruluk, piksel tabanlı sınıflama tekniği %70.24 genel doğruluk sağlamıştır. Deilmai vd. [5] tarafından yapılan çalışmada Malezya'da AKAÖ belirlemek için MOS ve DVM sınıflandırma yöntemlerinin doğruluklarını karşılaştırılmıştır, MOS sınıflandırma yönteminin %78, DVM sınıflandırma yönteminin %91 doğruluk sağladığı tespit edilmiştir. Yaban vd. [6] tarafından yapılan çalışmada orman alanlarında arazi örtüsü belirlemek için DVM ve MOS sınıflandırma yöntemlerini kullanılmış ve doğruluk analizi yapılmıştır, MOS yönteminin %70, DVM yönteminin %80 doğruluk sağladığı tespit. Yuh vd. [7] tarafından yapılan çalışmada arazi örtüsü belirlemek için Rastgele Orman (RO), DVM, YSA ve KEYK sınıflandırma yöntemlerini kullanılmış, KEYK sınıflandırma yöntemi %89.7, DVM sınıflandırma yöntemi %89, YSA sınıflandırma yöntemi %84, RO sınıflandırma yöntemi %99 doğruluk sağladığı tespit edilmiştir. Kavzoğlu ve Çölkesen [8] tarafından gerçekleştirilen çalışmada DVM'lerin sınıflandırma performansının kernel fonksiyonu ve parametre değerlerine bağlı olarak analiz edilmiştir. Çalışmada kullanılan veri seti için radyal tabanlı fonksiyon ve Pearson VII fonksiyon kernellerinin %94'ün üzerinde genel doğruluk sağlayarak en iyi performans gösteren yöntemler olduğu belirlenmiştir. Gümüş ve Durduran [9] tarafından gerçekleştirilen çalışmada Konya Kapalı Havzası içinde Beyşehir-Kaşaklı Alt Havzası'nda arazi kullanımı ve arazi örtüsünde meydana gelen zamansal değişim araştırılmıştır. 1984-2018 yılları arasındaki dönem incelenmiş ve DVM sınıflandırma işlemi sonucunda yapay yüzeylerin %418 oranında arttığı, ekilebilir tarım arazileri ve meraların %14 oranında azaldığı, ormanlar ve yarı doğal alanlar %4 ve kıyılardaki kıyı sulak alanları ise %6 arttığı tespit edilmiştir. Akar ve Güngör [10] tarafından gerçekleştirilen çalışmada kırsal ve kentsel alana ait QuickBird uydu görüntüsüne RO, DVM, Gentle AdaBoost (GAB), En Çok Benzerlik (EÇB) yöntemleri uygulanarak, yöntem doğrulukları karşılaştırılmıştır. En yüksek doğruluğu veren yöntem RO, DVM yönteminden kırsalda %11, kentsel alanda %10 daha iyi sonuç sağlamıştır. Doğan ve Buğday [11] tarafından gerçekleştirilen çalışmada Kastamonu ili 1999-2016 yılları arasında LULC değişimini tespit etmek için YSA piksel tabanlı sınıflama yöntemini kullanılmış,

sınıflandırma işlemleri 1999 ve 2016 yılları için sırasıyla %82 ve %84 oranlarıyla gerçekleştirilmiştir.

Bu çalışmanın temel amacı piksel tabanlı ve nesne tabanlı sınıflama yöntemlerinin, su alanları çevresinde AKAÖ belirlemek amacıyla kullanımında doğruluklarının araştırmaktır. Yedigöze barajı ve çevresinde, su yapıları, yerleşim alanları, tarım arazileri ve orman alanları bir arada bulunduğu için çalışma alanı olarak seçilmiştir. Sentinel-2B görüntülerinin analizi ile Yedigöze Barajı ve çevresinde AKAÖ belirlenmesi amacıyla piksel tabanlı sınıflandırma yöntemi olarak YSA, DVM ve MOS algoritması ve nesne tabanlı sınıflandırma tekniği olarak KEYK seçilmiş, su alanı, tarım alanı, orman ve yerleşim alanı olmak üzere dört sınıf oluşturulmuş, bu yöntemlerin doğrulukları kontrol noktaları kullanılarak analiz edilmiş ve sonuçlar karşılaştırılmıştır.

Çalışmanın "1. Giriş" bölümünde literatür çalışmalarına yer verilerek, çalışmanın temel amacı açıklanmıştır. "2. Materyal ve Metot" bölümünde, çalışma alanının konumu, kullanılan Sentinel-2B uydu görüntüsünün bantlarının ve özellikleri, çalışmada kullanılan görüntü sınıflama yöntemleri açıklanmıştır. "3. Bulgular ve tartışma" bölümünde, uydu görüntüsüne uygulanan ön işleme aşaması, sınıflama teknikleri kullanılarak oluşturulan sınıflama haritaları görüntüleri, her bir sınıf için hesaplanan piksel sayıları ve alanlar, hata matrisleri kullanılarak belirlenen doğruluk değerleri yer almaktadır. "4. Sonuç" bölümünde çalışma sonunda elde edilen tüm sonuçlar açıklanmıştır.

2 Materyal ve metot

2.1 Çalışma alanı

Yedigöze Barajı, hidroelektrik üretimi ve sulama amacıyla, 2007 yılında inşa edilmeye başlanmış ve 2010 yılında kullanıma açılmıştır. Yedigöze Barajı ve Hidroelektrik Santrali, Adana İl'inin kuzeyinde İmamoğlu ve Aladağ ilçeleri arasında, 37°24'05.42"N 35°26'43.07"E koordinatlarında yer almaktadır. Yedigöze Baraj Gölü etrafında ormanlık alanlar bulunmaktadır. Hem içerisinde su yapısı bulundurması hem de orman alanlarının bulunması nedeniyle, Yedigöze Baraj Gölü ve çevresi çalışma alanı olarak seçilmiştir. Çalışma alanı Şekil 1'de sunulmuştur.

2.2 Materyal


Bu çalışmada Yedigöze Barajı'nın 24 Haziran 2023 tarihinde algılanmış Sentinel-2B uydu görüntüsü kullanılmıştır. Sentinel-2B görüntüleri, AUA (Avrupa Uzay Ajansı) web sayfasından temin edilmiştir [12]. Tablo 1'de Sentinel-2B uydusunun bantlarının özellikleri yer almaktadır.

Çalışmada Sentinel-2B uydu görüntüsüne ait 10 metre çözünürlüğe sahip bant-2 (mavi), bant-3 (yeşil) ve bant-4 (kırmızı) kullanılmıştır.


2.3 Metot

2.3.1 Destek vektör makineleri (Support vector machines, DVM)


Kontrollü bir sınıflandırma tekniği olan DVM aynı zamanda bir öğrenme tekniğidir. Bu algoritma, bir hiper



(a)



(b)




(c)

Şekil 1. (a) Çalışma alanının konumu (b) çalışma alanı ve çevresine ait Sentinel-2B uydu görüntüsü (c) çalışma alanı [12,13]

Tablo 1. Sentinel-2B bantları ve özellikleri

Sentinel-2 Uydu Bantları	Özellikler	
	Dalgaboyu (mikrometre)	Çözünürlük(m)
Bant-1 (Kıyı Aerosol)	0.442	60
Bant-2 Mavi	0.492	10
Bant-3 Yeşil	0.559	10
Bant-4 Kırmızı	0.665	10
Bant-5 Bitki Örtüsü Kırmızı Kenar	0.703	20
Bant-6 Bitki Örtüsü Kırmızı Kenar	0.739	20
Bant-7 Bitki Örtüsü Kırmızı Kenar	0.779	20
Bant-8 NIR	0.833	10
Bant-8A Bitki Örtüsü Kırmızı Kenar	0.864	20
Bant-9 Su Buharı	0.943	60
Bant-10 SWIR Cirrus	1.376	60
Bant-11 SWIR	1.610	20
Bant-12 SWIR	2.185	20

düzlem olarak veri setini, bir dizi etiketli veri örneği kullanarak, önceden tanımlanmış bir sayıda sınıfa ayırmayı amaçlar [14]. DVM yönteminin yapısı Şekil 2’te sunulmuştur.



Şekil 2. DVM yönteminin yapısı [15]

$x \in R^N$ N boyutlu bir uzay ve $y \in \{-1+1\}$ olduğu için veri kümeleri $\{x_i, y_i\}$ ($i=1, \dots, k$)’dir. X, hiper düzlemde bir nokta olduğundan, bu hiper düzlem Denklem (1)’de tanımlanmıştır.

$$w \times x_i + b = 0 \quad (1)$$

İki sınıf için ayırıcı bir hiper düzlem tanımlanması Denklem (2), Denklem (3)’de sunulmuştur.

$$y = 1 \text{ için } w \times x_i + b \geq 1 \quad (2)$$

$$y = -1 \text{ için } w \times x_i + b \leq -1 \quad (3)$$

2.3.2 Maksimum olabirlik sınıflandırması (Maximum likelihood classification, MOS)

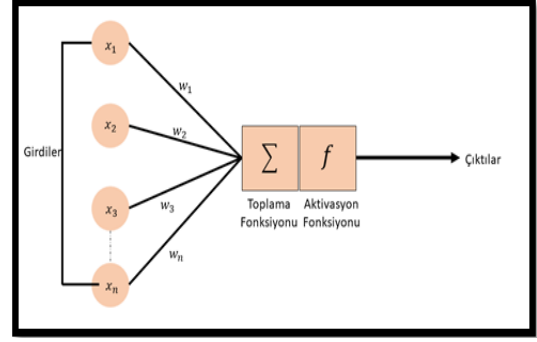
MOS, belirli bir istatistik için bilinen bir sınıf dağılımını maksimum olarak belirlemeye yönelik bir yöntemdir [16]. Uzaktan algılamada yaygın olarak kullanılan MOS, bir pikselin maksimum olasılığa karşılık gelen sınıfa atandığı bir piksel tabanlı sınıflama yöntemidir [17]. Matematiksel formülü Denklem (4)’de tanımlanmıştır.

$$P(X) = \ln(a_c) - [0.5x \ln(|S_x|)] - [0.5x(x - m_c)T_x(S_x^{-1})x(x - m_c)] \quad (4)$$

P olasılık değeridir, C örnek bir sınıfı temsil eder. x aday pikselin ölçüm vektörü, M sınıfın ortalama değeri, a aday pikselin sınıfa ait olma yüzdesi ve S_x varyans-kovaryans matrisi olarak tanımlanır [18].

2.3.3 Yapay sinir ağları (Artificial neural networks, YSA)

YSA, nöronlardan oluşan ve karmaşık ortamlarda tahmin etme ve tahmin için yararlı olan matematiksel bir modelleme aracıdır [19, 20]. Temel birimi nöronlar olup, nöronun yapısı Şekil 3’de sunulmuştur.



Şekil 3. Nöronun yapısı [20]

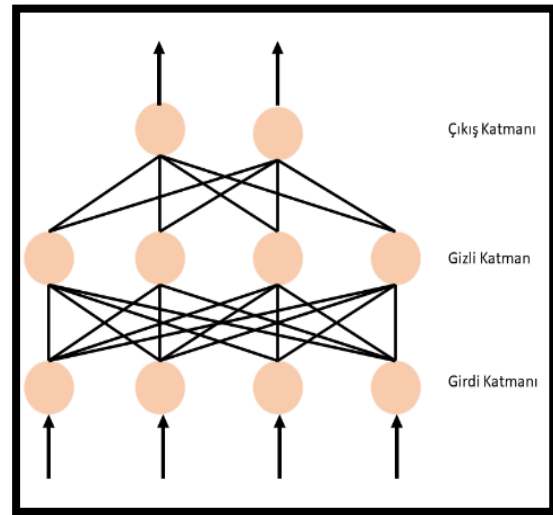
$x_1, x_2, x_3, \dots, x_n$ girdiler, $w_1, w_2, w_3, \dots, w_n$ bu girdilerin ağırlıklarıdır. Ağırlıklar girdilerin hücre üzerindeki etkisini belirler. Toplama fonksiyonu hücreye giren net girdiyi hesaplar. Bu matematiksel olarak Denklem (5)’de verildiği gibi tanımlanabilir [21].

$$Net\ Veri = \sum x_i w_i \quad (5)$$

Aktivasyon fonksiyonu Denklem (6)’de verildiği gibi tanımlanabilir.

$$y = F(x) \quad (6)$$

YSA, üç ana bölümden oluşur: Giriş katmanı dışarıdan gelen verileri alır ve gizli katmana aktarır. Gizli katman, giriş katmanından gelen verileri ağırlıkla çarparak verileri çıkış katmanına aktarır. Çıkış katmanı sonucu dışarıya gönderir [21]. YSA katmanları Şekil 4’te gösterilmiştir.



Şekil 4. YSA katmanları

2.3.4 K en yakın komşuluk yöntemi (K-nearest neighbor, KEYK)

KEYK yöntemi, nokta ile diğer değişkenler arasındaki benzerliklere dayanarak tahminde bulunan parametrik

olmayan bir yaklaşımdır [22]. KEYK nesne tabanlı bir sınıflandırma yöntemidir. Nesne tabanlı sınıflandırmanın ilk adımı segmentasyondur. Bu çalışmada çoklu çözünürlüklü segmentasyon kullanılmıştır. Çoklu çözünürlüklü segmentasyon algoritması bir birleştirme tekniğidir. Bireysel pikseller birden fazla düzeyde giderek daha büyük bölümler halinde toplanır. Üç parametreye dayanır: ölçek, şekil ve kompaktlık [23]. Bu yöntem tek görüntü nesnelere tanımlar ve homojenlik kriterine göre pikselleri komşularıyla birleştirir. Bu homojen kriterler, spektral ve şekil kriterlerinin birleşimidir. Ölçek parametresi görüntüde oluşacak olan segmentlerin ortalama boyutunu belirleyen değerdir. Çoklu çözünürlüklü segmentasyon aşamasında, ölçek parametresi, renk/şekil parametresi ve kompaktlık parametreleri çalışma alanına en uygun seçilmesi doğruluk açısından çok önemlidir. Renk/şekil ve kompaktlık parametreleri birbirini 1'e tamamlar [24].

KEYK algoritmasında ölçülen sonuçlara dayalı olarak stabil bir veri tabanı (D) oluşturulur. K en yakın komşu numarası belirlenir. Özellik vektörü olan M ($m_1, m_2 \dots m_n$) her nokta için hesaplanır ve üretilir. M' ve D koleksiyonunun her noktası arasındaki mesafeler (M): dist (M', M) belirlenirken yaygın olarak kullanılan Öklid Uzaklığı Denklem (7)'de sunulmuştur [25].

$$d(M', M) = \sqrt{\sum_{i=1}^n (m_i - m_j)^2} \quad (7)$$

Hesaplanan mesafeye göre en yakın K noktası D seçilir ve yukarıdaki denkleme (D_k) göre yeni bir veri toplanır. M'nin çıkış değeri Denklem (8)'kullanılarak D_k 'ye göre hesaplanır.

$$M' = \frac{\sum_{i=1}^K M_j}{K} \quad (8)$$

3 Bulgular ve tartışma

Kullanılan Sentinel-2B görüntüleri, LIC serisi olduğundan ve atmosferik düzeltmeleri yapılmış halde sunulduğundan dolayı, ön işleme aşamasında yalnızca görüntülerin kesilmesi işlemi yapılmıştır. İş akış diyagramı Şekil 5'te sunulmuştur.

Nesne tabanlı sınıflama aşamasında çoklu çözünürlüklü segmentasyon kullanılmıştır. Çalışmada farklı ölçek parametreleri denenmiş, parametre değerleri deneysel olarak seçilmiştir. Bu işlem gerçekleştirilirken şekil parametresi 0.1, kompaktlık parametresi 0.5, ölçek parametresi ise 80 olarak seçilerek çoklu çözünürlüklü segmentasyon gerçekleştirilmiştir. Çoklu çözünürlüklü segmentasyon uygulanmış görüntülere KEYK yöntemi ile nesne tabanlı sınıflama işlemi uygulanmıştır. KEYK uygulanırken komşuluk parametresi K, 1 olarak seçilmiştir. Çoklu çözünürlüklü segmentasyon uygulanmış görüntü ve KEYK yöntemi ile elde edilmiş sınıflama görüntüsü Şekil 6'de sunulmuştur.

DVM sınıflandırma yöntemi, kullanılan veri setleri doğrusal yapıya sahip ise sınıflandırılma yapılırken lineer

fonksiyonları kullanırken, uzaktan algılanmış görüntüler gibi doğrusal olmayan veri setleri olması durumunda kernel fonksiyonlarını kullanmaktadır [26]. Radyal tabanlı kernel fonksiyonu, yüksek sınıflandırma doğruluğu üretmesi nedeniyle DVM yöntemi uygulanırken en çok tercih edilen fonksiyon olma özelliğine sahiptir [8-26-27]. Radyal tabanlı kernel fonksiyonu Denklem (9)'de sunulmuştur.

$$K = (x_i x_j) = \exp(-\gamma \|x - y\|^2) \quad \gamma > 0 \quad (9)$$

Bu çalışmada DVM yöntemi uygulanırken Radyal tabanlı kernel fonksiyonu kullanılmıştır. Kernel fonksiyonu parametresinin (γ) ve C ceza parametresinin seçimi doğruluk açısından önemlidir. Buradaki C parametresi, iki düzlem arasındaki mesafeyi maksimum da tutarken esneme payını kabul edilebilir seviyede tutmak için kullanılan ceza faktörü olarak tanımlanmaktadır [28]. Bu parametrelerin seçiminde, grid arama yöntemi kullanılabilir. Grid arama yönteminde, parametreler için alt, üst sınır ve değer aralığı belirlenir, en iyi sınıflandırma performansını gösteren değerler parametre değerleri olarak kabul edilir [28]. Bu çalışmada γ parametresi, 0.333 ve C parametresi 100 olarak seçilmiştir.

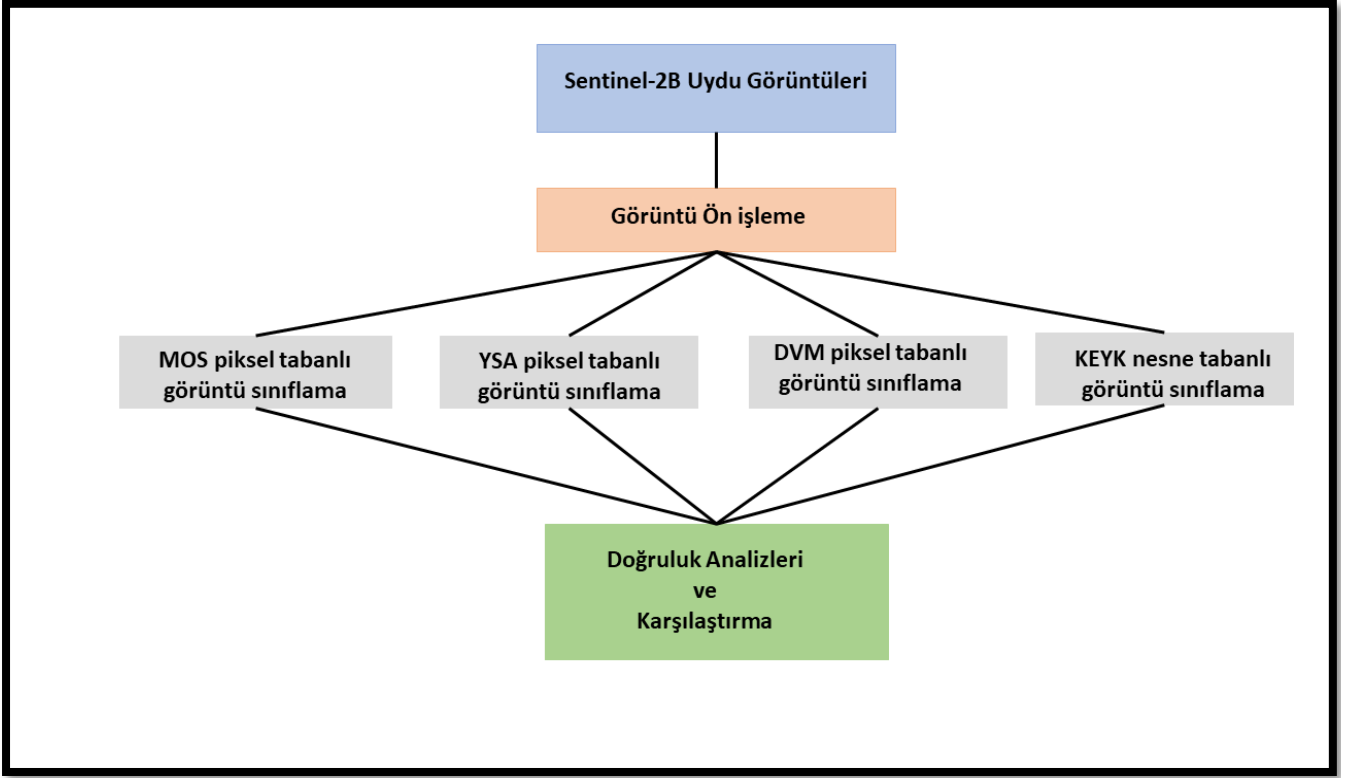
YSA yöntemi uygulanırken bir adet gizli katman kullanılarak, 100 iterasyon ile sınıflama işlemi gerçekleştirilmiştir. MOS, DVM ve YSA yöntemleri kullanılarak piksel tabanlı sınıflama işlemi gerçekleştirilmiş ve MOS, DVM, YSA sınıflama görüntüsü Şekil 7'de sunulmuştur.

MOS, YSA, DVM ve KEYK yöntemleri ile hesaplanan sınıf alanları Tablo 2'de sunulmuştur.

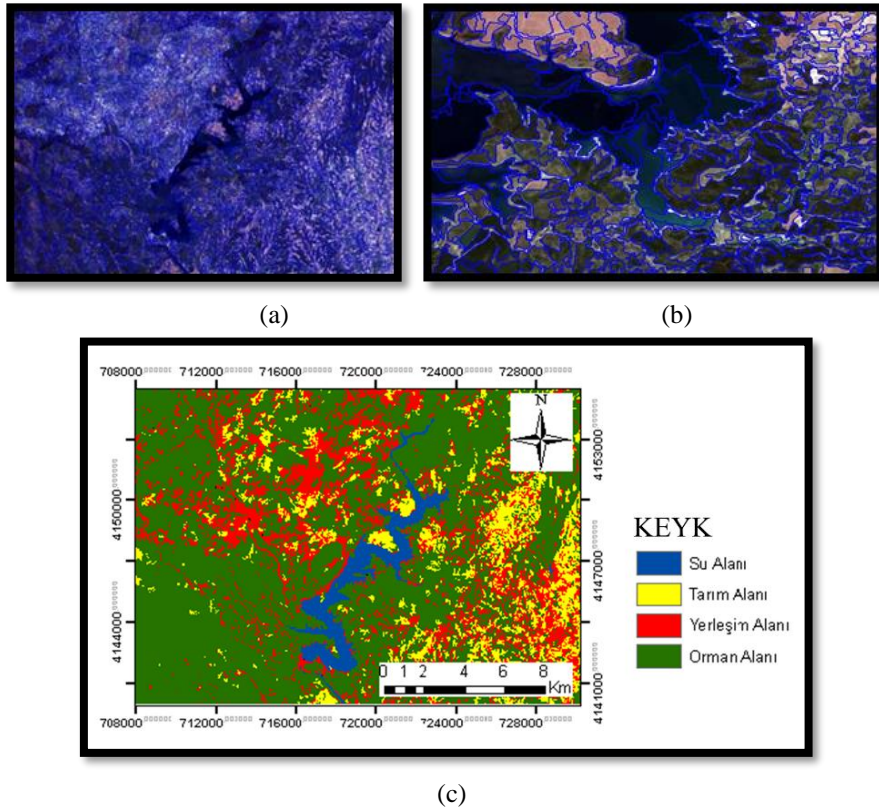
Tablo 2. MOS, YSA, DVM ve KEYK yöntemleri ile gerçekleştirilen sınıflama işlemi sonucu oluşturulmuş her sınıf için hesaplanan alanlar

	YSA (km ²)	DVM (km ²)	MOS(km ²)	KEYK (km ²)
Tarım alanı	54.3709	51.7583	40.1362	47.8719
Orman alanı	219.7825	226.4652	182.8332	231.8243
Yerleşim alanı	75.8512	71.6062	127.2243	70.3158
Su alanı	13.3758	13.5507	13.1867	13.3684
Toplam	363.3804	363.3804	363.3804	363.3804


Çalışma alanında, 100 adet kontrol noktası random olarak seçilmiştir. Bu noktalar, test alanlarının belirlenmesinde kullanılmıştır. Test alanları, arazi üzerinde yapılan gözlemler ve Google Earth Engine [29] yazılımı da kullanılarak oluşturulmuştur. Nokta sayısı literatürdeki çalışmalara göre seçilmiştir. Makineci ve Akosman [30] tarafından yapılan çalışmada kontrollü sınıflandırma doğruluk analizi, rastgele üretilmiş olan 100 adet test noktası ile yapılmıştır. Çiçekli [31] tarafından yapılan çalışmada random olarak üretilmiş 300 noktanın %30 u test verisi olarak kullanılmıştır. Noktaların dağılımı Şekil 8'de sunulmuştur. Oluşturulan hata matrisleri Şekil 9 'da sunulmuştur.




Şekil 5. İş akış diyagramı



Şekil 6. (a) ve (b) Çoklu çözünürlüklü segmentasyonu uygulanmış görüntüler (c) KEYK sınıflama haritası



Şekil 7. MOS, DVM ve YSA sınıflama haritaları



Şekil 8. Kontrol noktaları

MOS, YSA, DVM ve KEYK yöntemleri ile gerçekleştirilen sınıflama işlemlerinin genel doğrulukları Tablo 3'de, sınıflama üretici ve kullanıcı doğrulukları Tablo 4'de sunulmuştur.

Tablo 3. MOS, YSA, DVM ve KEYK yöntemleri ile gerçekleştirilen sınıflamaların genel doğrulukları

Yöntem	Genel Doğruluk (%)	Kappa
MOS	86.71	0.7744
YSA	92.42	0.8709
DVM	92.92	0.8678
KEYK	93.18	0.8990

MOS, YSA, DVM ve KEYK yöntemleri yüksek doğruluklu sonuçlar vermiştir. KEYK nesne tabanlı sınıflama yönteminin diğer yöntemlere göre daha yüksek doğruluk sağladığı gözlemlenmiştir.

Doğruluk sonuçları incelendiğinde, piksel tabanlı sınıflama yöntemlerinde tarım alanları ve yerleşim alanlarının doğrulukları daha düşüktür, yöntemlerin en çok tarım alanları ve yerleşim alanları birbirinden ayırmakta zorlandığı görülmektedir. Bunun nedeni yöntemlerin ekili olmayan tarım arazilerinin, yerleşim alanlarını ayırt etmekte başarısız olmasıdır. Nesne tabanlı sınıflama yöntemi segmentler oluşturularak sınıflama yaptığı için, piksel tabanlı sınıflama yöntemlerinden daha yüksek doğruluk sağlamıştır.

KEYK Nesne tabanlı sınıflandırma yöntemi, YSA, DVM ve MOS piksel tabanlı sınıflama tekniklerinden farklı olarak, sadece görüntüdeki spektral değeri değil, komşuluk özelliklerini de kullandığı için sınıflandırma işlemi yüksek doğrulukla gerçekleştirilmiştir. Literatürdeki nesne tabanlı

ve piksel tabanlı sınıflandırma tekniklerini kullanan arazi kullanımı ve arazi örtüsü çalışmaları incelendiğinde [1, 2, 3-4] nesne tabanlı sınıflama tekniği ile daha iyi bir sınıflama doğruluğu elde ederek harita yapımı gerçekleştirilmiştir. Literatürdeki çalışmalarda elde edilen doğruluk değerleri ile karşılaştırıldığında bu çalışmada elde edilen sonuçlarla (Tablo 3) uyum sağladığı görülmektedir.

MOS en düşük doğruluğu sağlayan sınıflandırma yöntemi olmuştur. Literatürdeki MOS yöntemini kullanan çalışmalar incelendiğinde [5, 6], bu çalışmada elde edilen sonuçlarla (Tablo 3) uyumlu olduğu görülmektedir.

Çiçekli vd. [15] tarafından yapılan çalışmada Hirfanlı Baraj Gölü çevresinde AKAÖ'yü YSA yönteminin %94, DVM yönteminin %89, ve KEYK yönteminin %88 doğruluk ile tespit etmiştir. Adam vd. [32] tarafından yapılan çalışmada Sudan'da yarı kurak alanlarda AKAÖ, nesne ve piksel tabanlı sınıflama yaparak doğruluklarını karşılaştırılmıştır. MOS, KEYK ve bulanık mantık kullanılan çalışmada, piksel tabanlı sınıflamanın 72.92%, nesne tabanlı sınıflamanın %54 doğruluk verdiği tespit edilmiştir. Çalışmalar incelendiğinde [10, 15, 30] çalışma alanına uygun olarak yöntem seçimi yapılması gerektiği sonucuna varılmıştır.

Yedigöze Baraj Gölü, Seyhan nehri ile Çatalan Baraj Gölü ve Adana Seyhan baraj gölüne bağlı olup, bölge için önemli bir su kaynağıdır. Ayrıca çevresinde orman alanları bulunmaktadır. Orman alanları, özellikle yaz mevsiminde meydana gelen orman yangınları nedeniyle düzenli olarak gözlemlenmesi ve takibi gereken alanlardır. Literatürde Yedigöze Barajı ve çevresi ile ilgili AKAÖ çalışması yer almamaktadır. Bu çalışma ile bölgede AKAÖ belirlemek ve ilerleyen zamanlarda AKAÖ değişimini tespit etmek için en uygun yöntemin KEYK olduğu tespit edilmiştir.

4 Sonuçlar

Zaman içerisinde nüfus artmakta, yaşam için en önemli kaynak olan su önem kazanmakta, su kaynaklarının yönetimi konusu gündeme gelmektedir. Bu nedenle su alanlarının gözlenmesi gereklidir. Teknolojinin gelişmesi ile birlikte sıklıkla kullanılmaya başlayan uydu teknolojileri, sulak alanların gözlemlenmesi konusunda birçok yöntem sunmuştur.

Bu çalışmada, Sentinel-2 uydu verileri kullanılarak Yedigöze Baraj Gölü ve çevresinde AKAÖ'nün belirlenmesi için hem piksel tabanlı (DVM, YSA MOS) hem de nesne tabanlı (KEYK) görüntü sınıflandırma yöntemleri kullanılmış ve doğruluk analizi yapılmıştır.

Tablo 4. MOS, YSA, DVM ve KEYK yöntemleri ile gerçekleştirilen sınıflamaların üretici ve kullanıcı doğrulukları

Sınıflar	YSA		DVM		MOS		KEYK	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Orman Alanı	99.10	91.61	93.91	99.63	87.75	97.91	87.8	100
Yerleşim Alanı	80.79	88.61	91.33	71.08	81.57	80.31	93	83.3
Tarım Alanı	84.94	99.99	88.51	92.19	99.15	55.05	100	88.1
Su Alanı	99.56	96.75	99.71	99.11	99.99	89.74	100	100

		YSA				
		Tarım Alanı	Orman Alanı	Yerleşim Alanı	Su Alanı	Toplam
GERÇEK	Tarım Alanı	543648	11	50	0	543709
	Orman Alanı	24039	2013473	159738	575	2197825
	Yerleşim Alanı	72369	14010	672133	0	758512
	Su Alanı	0	4337	13	129408	133758
	Toplam	640056	2031831	831934	129983	3633804

		MOS				
		Tarım Alanı	Orman Alanı	Yerleşim Alanı	Su Alanı	toplam
GERÇEK	Tarım Alanı	220937	0	180425	0	401362
	Orman Alanı	0	1790129	38203	0	1828332
	Yerleşim Alanı	1890	248649	1021695	9	1272243
	Su Alanı	0	1367	12166	118334	131867
	Toplam	222827	2040145	1252489	118343	3633804

		KEYK				
		Tarım Alanı	Orman Alanı	Yerleşim Alanı	Su Alanı	toplam
GERÇEK	Tarım Alanı	37	0	0	0	37
	Orman Alanı	4	29	0	0	33
	Yerleşim Alanı	1	0	15	0	16
	Su Alanı	0	0	0	9	9
	Toplam	42	29	15	9	95

		DVM				
		Tarım Alanı	Orman Alanı	Yerleşim Alanı	Su Alanı	toplam
GERÇEK	Tarım Alanı	477163	12	40408	0	517583
	Orman Alanı	37	2256332	7894	389	2264652
	Yerleşim Alanı	61884	145226	508951	1	716062
	Su Alanı	0	1199	4	134304	135507
	Toplam	539084	2402769	557257	134694	3633804

Şekil 9. Hata matrisleri

Nesne-tabanlı sınıflandırmada, piksel tabanlı sınıflandırmadan farklı olarak segmentasyon aşamasında yansıma değerlerine göre benzer olan piksellerden oluşan segmentler elde edilmektedir ve böylece çalışma bölgesine ait sınıflar kolayca oluşturulabilmektedir. Oluşan segmentler, bir sınıf için bir bütünlük sağlar ve bu durum daha kolay bir sınıflandırma işlemini ve sınıflama doğruluğunu ortaya koymaktadır. Bu nedenle KEYK sonuçları diğerlerinden daha yüksek doğruluk sağlamıştır. MOS en düşük doğruluğu sağlarken, DVM ve YSA sonuçları birbirine yakın çıkmıştır.

Doğruluk sonuçları göz önüne alındığında, tüm sınıflandırma teknikleri tatmin edici sonuçlar sunmaktadır. Elde edilen sonuçlar, su alanları ve çevresinde AKAÖ çalışmalarında hem piksel tabanlı sınıflandırma yöntemlerinin hem de nesne tabanlı sınıflandırma yöntemlerinin kullanılabilirliğini göstermektedir. Yedigöze Baraj Gölü ve çevresi için en uygun sınıflandırma yönteminin KEYK olduğu tespit edilmiştir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (Turnitin): % 17

Kaynaklar

- [1] M. Gholoobi, A. Tayyebi, M. Taleyi and A. H. Tayyebi, Comparing pixel based and object-based approaches in land use classification in mountainous areas. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, 38 (8), 789-794, Kyoto, Japan,2010.
- [2] K. Kalkan ve D. Maktav, Nesne tabanlı ve piksel tabanlı sınıflandırma yöntemlerinin karşılaştırılması (IKONOS Örneği). III. UZAL-CBS, Gebze, 2010.
- [3] H. Zhang, Q. Li, L. Liu, X. Du, T. Dong, H. McNairn, C. Champagne, M. Liu and J. Shang, Object-based crop classification using multi-temporal SPOT-5 imagery and textural features with a random forest classifier. Geocarto International, 33(10), 1017-1035, 2018.<https://doi.org/10.1080/10106049.2017.1333533>.
- [4] A. M. Al Fugara, B. Pradhan and T. A. Mohamed, Improvement of land-use classification using object-oriented and fuzzy logic approach. Applied Geomatics, 1(4), 111-120, 2019.<https://doi.org/10.1007/s12518-009-0011-3>.
- [5] B. R. Deilmay, B. B. Ahmad and H. Zabihi, Comparison of two classification methods (MLC and SVM) to extract land use and land cover in Johor Malaysia. In IOP conference series: Earth and environmental science, 20(1), 1-6, 2014.
- [6] M. Yaban, M. A. S. B. Azmi, M. Z. Zakaria and M. M. Isa, Comparison of support vector machines (SVMs) and maximum likelihood classification (MLC) for Nipa Palm (*Nypa fruticans*) extent in East Coast of Sabah, Malaysia. Asian Conference on Remote Sensing (ACRS 2022), 1-8, 2022.
- [7] Y. G. Yuh, W. Tracz, H. D. Matthews, and S. E. Turner, Application of machine learning approaches for land cover monitoring in northern Cameroon. Ecological informatics, 74, 1-15, 2023.<https://doi.org/10.1016/j.ecoinf.2022.101955>
- [8] T. Kavzoğlu, İ. Çölkesen, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. Harita Dergisi, 144, 73-82, 2010.
- [9] M. G. Gümüş, S. S. Durduran. The performance analyses of support vector machine classifiers for examination of the temporal change of land-use/cover in the Beyşehir Basin in Turkey (1984-2018). Jeodezi Ve Jeoinformasyon Dergisi, 8(1), 57-71, 2021. <https://doi.org/10.9733/JGG.2021R0005.E>.
- [10] Ö. Akar, O. Güngör. Rastgele Orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. Jeodezi ve Jeoinformasyon Dergisi, 106, 139-146, 2012. <https://doi.org/10.9733/jgg.241212.1t>
- [11] S. Doğan, E. Buğday, E. Modeling of temporal and spatial changes of land cover and land use by artificial

- neural networks: Kastamonu Sample. Bartın Orman Fakültesi Dergisi, 20(3), 653-663, 2018.
- [12] ESA, European Space Agency Data Hub. <https://scihub.copernicus.eu/dhus/#/home>, Accessed 20 April 2024.
- [13] T.C. Milli Savunma Bakanlığı Harita Genel Müdürlüğü. <https://www.harita.gov.tr/urunler/>, Accessed 07 June 2024.
- [14] G. Mountrakis, J. Im and C. Ogole, Support vector machines in remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing, 66, 247–259, 2011.
- [15] S.Y. Çiçekli, A. Şekertekin, N. Arslan, C. Dönmez, Comparison of pixel and object-based classification methods in wetlands using Sentinel-2 Data. 3rd International Mediterranean Science and Engineering Congress (IMSEC 2018), 298-302, 2018.
- [16] A. J. Scott and M. J. Symons, Clustering methods based on likelihood ratio criteria. Biometrics, 27 (2), 387–397, 1971.
- [17] L. Kimfung, W. Shi and H. A. Zhang, Fuzzy topology-based maximum likelihood classification. ISPRS Journal of Photogrammetry and Remote Sensing, 66, 103-114, 2011.
- [18] S. Bulut ve A. Günlü, Arazi kullanım sınıfları için farklı kontrollü sınıflandırma algoritmalarının karşılaştırılması. Kastamonu University Journal of Forestry Faculty, 16 (2), 528–535, 2016. <https://doi.org/10.17475/kastorman.289762>.
- [19] M. M. Hamed, M. G. Khalafallah and E. A. Hassani, Prediction of wastewater treatment plant performance using artificial neural networks. Environmental Modelling & Software, 19(10), 919-928, 2004. <https://doi.org/10.1016/j.envsoft.2003.10.005>
- [20] M. S. Nasr, M. A. E. Moustafa, H. A. E. Seif and G. E. Kobrosy, Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT. Alexandria Engineering Journal, 51(1), 37-43, 2012. <https://doi.org/10.1016/j.aej.2012.07.005>
- [21] S. Haykin, Neural networks: a comprehensive foundation. Macmillan College Publishing Company, 1994.
- [22] R. E. McRoberts, M. D. Nelson and D. G. Wendt, Stratified estimation of forest area using satellite imagery, inventory data, and the k-Nearest Neighbors technique. Remote Sensing of Environment, 82(2-3), 457-468, 2002. [https://doi.org/10.1016/S0034-4257\(02\)00064-0](https://doi.org/10.1016/S0034-4257(02)00064-0)
- [23] C. Witharana and D. L. Civco, Optimizing multi-resolution segmentation scale using empirical methods: Exploring the sensitivity of the supervised discrepancy measure Euclidean distance 2 (ED2). ISPRS Journal of Photogrammetry and Remote Sensing, 87, 108-121, 2014. <https://doi.org/10.1016/j.isprsjprs.2013.11.006>
- [24] A. Sabuncu, F. Sunar. Ortofotolar ile nesne tabanlı görüntü sınıflandırma uygulaması: Van-Erciş depremi örneği. Artvin Çoruh Üniversitesi Doğal Afetler Uygulama ve Araştırma Merkezi Doğal Afetler Ve Çevre Dergisi, 3(1), 1-8, 2017. <https://doi.org/10.21324/dacd.271091>
- [25] L. Sang, Y. Xu, R. Cao, Y. Chen, Y. Guo, R. Xu. Modelling of GaN HEMT by using an improved k-nearest neighbors algorithm. Journal of Electromagnetic Waves and Applications, 25(7), 949-959, 2011. <https://doi.org/10.1163/156939311795254019>
- [26] İ. Çölkese, T. Yomralıoğlu, Arazi örtüsü ve kullanımının haritalanmasında WorldView-2 uydu görüntüsü ve yardımcı verilerin kullanımı. Harita Dergisi. 80(152), 12 – 24, 2014.
- [27] T. Kavzoglu, I. Colkesen, A kernel functions analysis for support vector machines for land cover classification. International Journal of Applied Earth Observation and Geoinformation, 11, 352–359, 2009. <https://doi.org/10.1016/j.jag.2009.06.002>
- [28] M. Ayaz, Makine öğrenmesi algoritmaları ile covid-19 hastalarının belirlenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, 2021.
- [29] Google LLC, 2024. Google Earth Engine (Computer software) <https://earthengine.google.com>. Accessed 06.05.2024.
- [30] H. B. Makineci, E. N. Akosman. Sentinel-2A verileriyle Trabzon İli 2019-2020 yılları arasında ortaya çıkan sınıflandırma farklarının çeşitli algoritmalarla değerlendirilmesi. Türkiye Uzaktan Algılama Dergisi, 5(2), 78–88, 2023. <https://doi.org/10.51489/tuzal.1383784>
- [31] S.Y. Çiçekli. Otomatize edilmiş nesne tabanlı arazi örtüsü sınıflandırma modeli: Aşağı Seyhan Ovası Örneği. Doktora Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, 2022.
- [32] H. E. Adam, E. Csaplovics, M. F. Elhaja. A comparison of pixel-based and object-based approaches for land use land cover classification in semi-arid areas, Sudan. 8th IGRSM International Conference and Exhibition on Remote Sensing&GIS, 2016.

