

## Uydu Görüntüleri Kullanarak Makine Öğrenme Yöntemleri ile Arazi Kullanımı ve Arazi Örtüsünün Belirlenmesi

Sevim Yasemin OTURANÇ<sup>1\*</sup>

<sup>1</sup>Jeoloji Mühendisliği Bölümü, Mühendislik Fakültesi, Çukurova Üniversitesi, Adana, Türkiye

\*<sup>1</sup> s.y.cicekli@gmail.com

(Geliş/Received: 19/04/2024;

Kabul/Accepted: 25/10/2024)

**Öz:** Uydu teknolojilerinin gelişmesiyle birlikte, arazi kullanımı ve arazi örtüsü belirlemek amacıyla uzaktan algılama teknikleri daha sık kullanılmaktadır. Nergizlik barajı önemli bir su kaynağı olup, çevresinde yerleşim alanları, tarım arazileri ve orman alanları bir arada bulunduğu için arazi örtüsünün düzenli olarak gözlemlenmesi gereklidir. Bu çalışmanın temel amacı Nergizlik Baraj Gölü çevresinde piksel tabanlı görüntü sınıflandırma yöntemleri ile sınıflama işlemi uygulayarak ve bant oranlama teknikleri kullanarak arazi kullanımı ve arazi örtüsünü belirlemek, bu tekniklerin genel doğruluklarını karşılaştırmak ve çalışma alanına en uygun yöntemi tespit etmektir. Bu çalışmada Nergizlik Baraj Gölü'nün 3 Ocak 2024 tarihinde alınan Sentinel-2B uydu görüntüsü kullanılmıştır. Görüntü, kırmızı, mavi ve yeşil bantları kullanılarak, Support Vector Machines (SVM), Artificial Neural Networks (ANN) yöntemiyle piksel tabanlı sınıflandırma yöntemiyle sınıflandırılmıştır. Görüntüye Normalized Difference Vegetation Index (NDVI), Normalized Difference Red Edge Index (NDRE) bant oranlama teknikleri de uygulanmıştır. Arazi kullanımı ve arazi örtüsü haritaları oluşturulmuştur. Bu çalışmada SVM %89, ANN %88, NDVI %81, NDRE %84 doğruluk sağlamıştır. Tüm yöntemler beklenen doğruluğu sağlamış olup, piksel tabanlı SVM sınıflama yönteminin diğer yöntemlere göre daha yüksek doğruluk sağladığı tespit edilmiştir.

**Anahtar kelimeler:** Destek Vektör Makineleri, Yapay Sinir Ağları, Normalize Edilmiş Fark Bitki Örtüsü İndeksi, Normalize Edilmiş Fark Kırmızı Kenar İndeksi, Sentinel-2B.

### Determination of Land Use and Land Cover by Machine Learning Methods Using Satellite Images

**Abstract:** With the development of satellite techniques, remote sensing techniques are used more frequently in remote sensing studies to determine land use and land cover. Nergizlik Reservoir is an important water source and since residential areas, agricultural lands and forest areas are located around it, regular observation of the land cover is necessary. The main purpose of this study is to determine land use and land cover around Nergizlik Reservoir by pixel-based image classification methods, band ratio techniques and to compare the general accuracy of these techniques and to determine the most appropriate method for the field of study. In this study, Sentinel-2B satellite image of Nergizlik Reservoir taken on January 3, 2024 was used. The image was classified by Support Vector Machines (SVM) and Artificial Neural Networks (ANN) pixel-based classification method using red, blue and green bands. Normalized Difference Vegetation Index (NDVI) and Normalized Difference Red Edge Index (NDRE) band ratio techniques were applied to the image. Land use and land cover maps were created. SVM provided 89% accuracy, ANN 88%, NDVI 81%, NDRE 84%. All methods provided the expected accuracy and the pixel-based SVM classification method provided higher accuracy than other methods.

**Key words:** Support Vector Machines, Artificial Neural Networks, Normalized Difference Vegetation Index, Normalized Difference Red Edge Index, Sentinel-2B.

#### 1. Giriş

Uzaktan algılama teknolojilerindeki gelişmeler ile, Arazi Kullanımı, Arazi Kullanım Değişikliği ve Ormancılık (Land Use, Land-Use Change, and Forestry, LULUCF) haritaları oluşturmak, arazi kullanımı ve arazi örtüsü değişikliklerini tespit etmek, sulak alan yönetimi, ekolojik çalışmalar ve doğal afetlerin izlenmesi için uydu tekniklerinin kullanımı yaygınlaşmıştır. Nüfus artışı ile birlikte su ve sulak alanların gözlemlenmesi ve su yönetimi büyük önem kazanmıştır. Su alanları ve çevresinde, LULUCF haritaları, gözlem ve takip açısından sınıflandırma algoritmaları ve bant oranlama teknikleri kullanılarak oluşturulabilir ve izlenebilir.

Literatürde Artificial Neural Networks (ANN), Support Vector Machines (SVM) piksel tabanlı sınıflama yöntemleri ve Normalized Difference Vegetation Index (NDVI), Normalized Difference Red Edge Index (NDRE) bant oranlama teknikleri üzerine birçok çalışma bulunmaktadır. Pakhale ve Gupta, Karnal bölgesinde ANN ve SVM yöntemleri ile piksel tabanlı sınıflama için kullanmış, bu teknikleri obje tabanlı sınıflama yöntemi ile karşılaştırmıştır. Objeye tabanlı sınıflama tekniklerinin daha yüksek genel doğruluk sağladığı tespit edilmiştir [1].

\* Sorumlu yazar: [s.y.cicekli@gmail.com](mailto:s.y.cicekli@gmail.com). Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-8140-1265

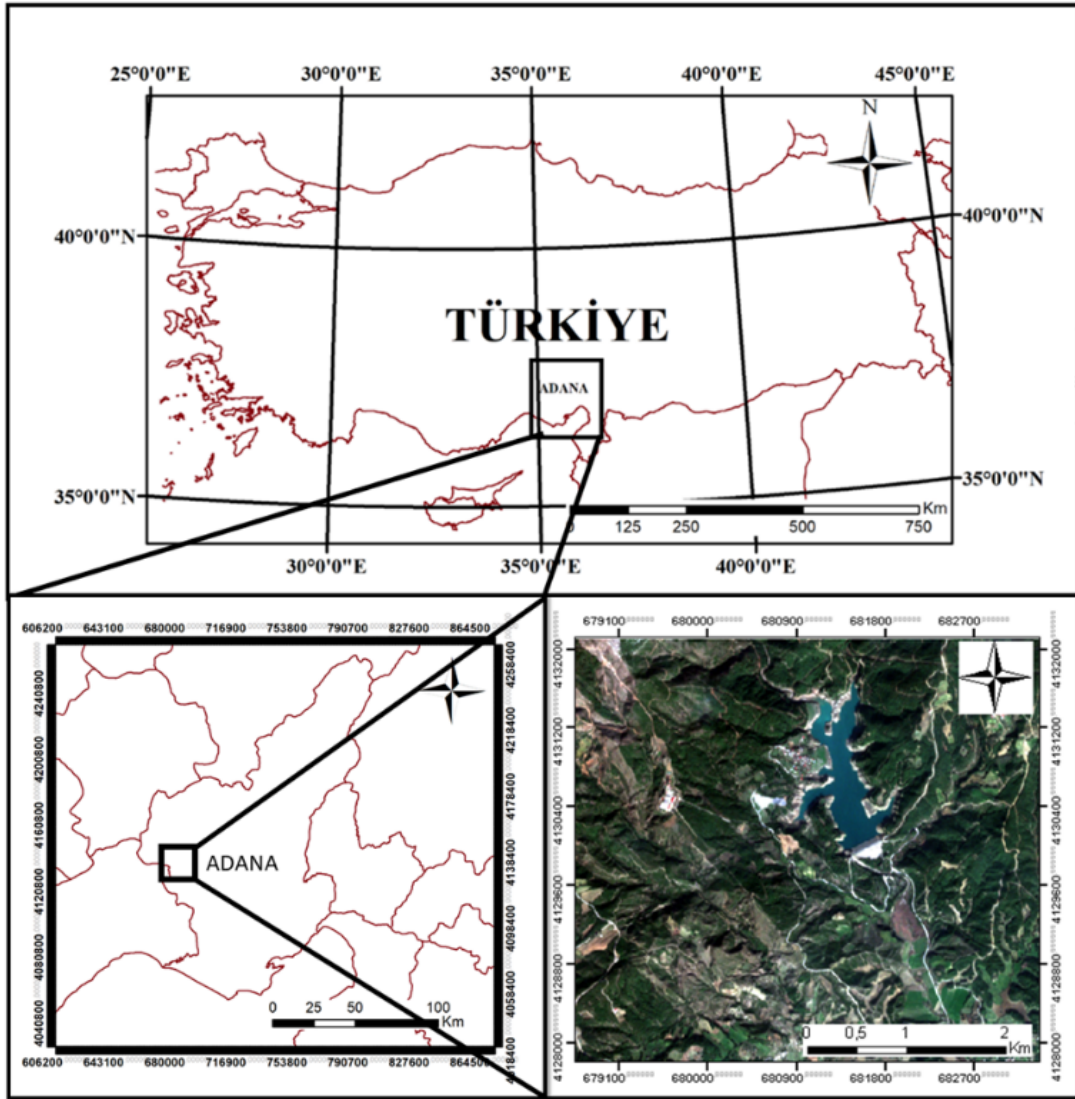
Deilmari ve ark., ANN ve Maximum Likelihood Classification (MLC) piksel tabanlı sınıflama yöntemlerinin doğruluklarını karşılaştırmış ve bu yöntemlerle Johar Malezya’da orman alanlarında değişimleri hesaplamıştır. ANN yöntemi MLC ‘den daha yüksek doğruluk sağlamıştır. Her iki yöntemle de değişim miktarları tespit edilmiştir [2]. Pujari ve ark., SVM ve ANN piksel tabanlı sınıflama yöntemlerini bitki hastalıklarını sınıflamak için kullanmıştır. SVM yönteminin ANN yöntemine göre daha kullanışlı olduğu tespit edilmiştir [3]. Kuc ve Chormański, Warsaw bölgesine ait Sentinel-2 görüntüleri kullanarak Normalized Difference Built-up Index (NDBI) ve NDVI yöntemi ile şehir haritaları oluşturmuştur [4]. Özdarıcı Ok, Mersin bölgesinde GeoEye uydu görüntülerini kullanarak NDVI yöntemi ile ağaçları %65-%90 doğrulukla tespit etmiştir [5]. Ustuner ve ark., RapidEye uydu görüntülerine NDVI, Green Normalized Difference Vegetation Index (GNDVI), NDRE bant oranlama teknikleri ve SVM görüntü sınıflama yöntemi uygulamış ve ürün tipi sınıflaması yapmıştır, çalışma sonucunda NDRE yönteminin görüntü sınıflandırma doğruluğu konusunda diğer indekslere göre yüksek olduğu ve ürün sınıflandırmasında SVM yöntemi başarılı olduğu tespit edilmiştir [6]. Doğan ve Buğday, 1999-2016 yılları arasında LULUCF değişimini ANN ile tespit etmiştir. 1999 yılı görüntüsü için %82, 2016 yılı için %84 doğruluk sağlamıştır [7]. Yuh ve ark., Random Forest (RF), ANN, SVM ve K- nearest neighbor (KNN) sınıflama yöntemlerini karşılaştırmıştır. KNN %89,7, SVM %89, ANN %84 ve RF %99 doğruluk sağlamıştır [8]. Çiçekli ve ark., Hirfanlı Baraj Gölü çevresinde LULUCF tespit etmek için ANN, SVM ve KNN kullanmıştır. ANN %94, SVM %89, KNN %88 doğruluk sağlamıştır [9]. Boiarskii ve Hasegawa, insansız hava aracı kullanılarak elde edilmiş görüntüleri NDVI ve NDRE uygulamış, NDRE yönteminin bitki örtüsü tespitinde daha yüksek doğruluklu ve klorofil içeriğine daha hassas olduğunu tespit etmiştir [10]. Naguib ve Daliman, Malezya Kalentan bölgesine ait Sentinel-2A ve Landsat 8 uydu görüntülerine NDVI ve NDRE tekniklerini uygulamıştır. NDRE tekniğinin bitki örtüsü ile daha uyumlu sonuçlar verdiğini tespit etmiştir [11]. Çınar ve ark., Gölhisar, Burdur bölgesine ait Sentinel-2A görüntülerine NDVI, NDRE ve Plant Senescence Reflectance Index (PSRI) uygulayarak bitkilerde kök çürüklüğünü araştırmıştır. NDRE, %89, NDVI %87, PSRI %86 doğruluk sağlamıştır [12]. Borgogno-Mondino ve ark., nar bahçeleri üzerine yaptıkları çalışmada Sentinel-2 görüntülerine NDVI, NDRE ve Normalized Difference Water Index (NDWI) yöntemlerini uygulamış ve NDRE yönteminin daha çok bitki özelliği ayırt edebildiğini tespit etmiştir [13]. Nergizlik barajı ve çevresinde, su yapıları, yerleşim alanları, tarım arazileri ve orman alanları bir arada bulunduğu için çalışma alanı olarak seçilmiştir. Bant oranlama teknikleri ve piksel tabanlı sınıflama teknikleri bir arada kullanılarak, çalışma alanına en uygun LULUCF belirleme yönteminin tespit edilmesi hedeflenmiştir.

Bu çalışmanın temel amacı piksel tabanlı sınıflama yöntemleri ve bant oranlama tekniklerini bir arada kullanarak, su alanlarında ve çevresinde LULUCF belirlemek amacıyla kullanımında performanslarını araştırmak ve çalışma alanı için en uygun yöntemi tespit etmektir. Sentinel-2B görüntülerinin analizi ile Nergizlik Barajı yakınında LULUCF belirlenmesi amacıyla ANN, SVM algoritmaları ve NDVI, NDRE bant oranlama teknikleri seçilmiş, su alanı, bitki örtüsü ve diğer alanlar olmak üzere üç sınıf oluşturulmuş, bu yöntemlerin doğrulukları kontrol noktaları kullanılarak analiz edilmiş ve sonuçlar karşılaştırılmıştır. İki farklı kontrollü sınıflama yöntemi ve iki farklı bant oranlama tekniğinin kullanılmış olması ile literatüre katkı sağlayacağı düşünülmektedir. 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” bölümünde, uydu görüntüsüne uygulanan ön işleme aşaması, sınıflama teknikleri kullanılarak oluşturulan sınıflama haritaları görüntüleri, her bir sınıf için hesaplanan piksel sayıları ve alanlar, belirlenen doğruluk değerleri yer almaktadır. “4. Tartışma” bölümünde, elde edilen sonuçlar literatürle karşılaştırılmıştır. “5. Sonuç” bölümünde çalışma sonunda elde edilen tüm sonuçlar açıklanmıştır.

## 2. Materyal ve Yöntem

### 2.1 Çalışma Alanı

Çalışma Alanı Adana ili’nin kuzeyinde Karaisalı ilçesinde yer alan sulama ve taşkın önleme amaçlı inşa edilmiş Nergizlik Baraj Gölü ve çevresidir (Şekil 1). Adana il merkezine 58 km, Karaisalı ilçe merkezine 8 km uzaklıktadır. Nergizlik barajı ve çevresinde, yerleşim alanları, tarım arazileri ve orman alanları bir arada bulunmakta olup, hem önemli bir su kaynağı olup, hem de çevresinde bitki örtüsü bulunduğu için çalışma alanı olarak seçilmiştir.



Şekil 1. Çalışma alanı [14][15].

## 2.2 Materyal

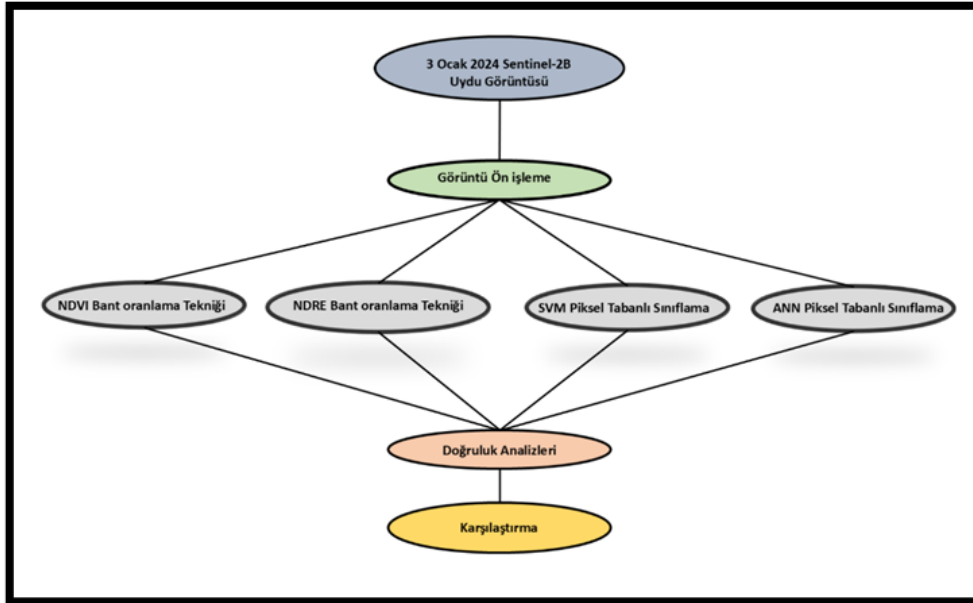
Bu çalışmada Karaisalı İlçesi Nergizlik Baraj gölü çevresine ait European Space Agency (ESA) web sayfasından temin edilen 3 Ocak 2024 tarihinde algılanmış Sentinel-2B uydu görüntüsü kullanılmıştır [14]. Uydu görüntüsü seçiminde bulutluluk durumu dikkate alınmıştır. Sentinel-2B uydusunun bantlarının özellikleri aşağıdaki gibidir (Tablo 1).

## 2.3 Yöntem

Sentinel-2B görüntüleri, ESA web sayfasından temin edilmiştir [14]. Kullanılan görüntüler, LIC serisi olduğundan ve atmosferik düzeltmeleri yapılmış halde sunulmuş olduğundan ön işleme aşamasında yalnızca görüntüler kesilmiştir. Ayrıca kırmızı kenar bantı 20 metre çözünürlüğe sahip olduğu için NDRE bant oranlama tekniği uygulanırken NIR bantı 20 metreye yeniden örneklenerek kullanılmıştır (Şekil 2). Yeniden örnekleme, nearest neighbor, biliner enterpolasyon ve kübik yöntemlerle yapılabilir. Optik uydu görüntülerinin bantlarının yeniden örnekleme en çok kullanılan yöntem nearest neighbor yöntemidir [16]. Bu nedenle nearest neighbor yöntemi kullanılmıştır.

**Tablo 1.** Sentinel-2 bantları ve özellikleri.

Sentinel-2 Uydu Bantları	Özellikler	
	Dalgaboyu (micrometre)	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



**Şekil 2.** İş akış diyagramı.

Normalize Edilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index, NDVI); bitki örtüsü tespit etmek için sıklıkla kullanılan bir yöntemdir [17]. NIR ve kırmızı bantları kullanır [18-19]. NDVI, -1 ve +1 arasında değer alır [10]. Yüksek değerler sağlıklı bitki örtüsünü temsil eder. Formülü Denklem 1'deki gibidir.

$$NDVI = \frac{BANT_{NIR} - BANT_{KIRMIZI}}{BANT_{NIR} + BANT_{KIRMIZI}} \quad (1)$$

Bitki örtüsü tespit etmek için Normalize Edilmiş Fark Kırmızı Kenar İndeksi (Normalized Difference Red Edge Index, NDRE) sıklıkla kullanılan bir yöntem olup, NIR ve kırmızı kenar bantları kullanır [20]. Formülü Denklem 2'deki gibidir.

$$NDRE = \frac{BANDT_{NIR} - BANT_{KIRMIZI KENAR}}{BANT_{NIR} + BANT_{KIRMIZI KENAR}} \quad (2)$$

NDRE, -1 ve +1 arasında değer alır. Yüksek değerler daha sağlıklı ve daha klorofil düzeyi yüksek bitki örtüsünü temsil eder [21].

Destek Vektör Makineleri (Support Vector Machines, SVM) bir öğrenme tekniğidir ve aynı zamanda kontrollü bir sınıflandırma tekniği olarak da kullanılır. Bu algoritma, veri setini, bir dizi etiketli veri örneği ile kullanılan, önceden tanımlanmış ayrı bir sayıda sınıfa ayıran bir hiper düzlem bulmayı amaçlar [22].

$x \in \mathbb{R}^N$  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 3'de tanımlanmıştır.

$$w \times x_i + b = 0 \quad (3)$$

İki sınıf için ayrı bir hiper düzlem tanımlanması Denklem 4 ve Denklem 5'de sunulmuştur.

$$y = 1 \text{ için } w \times x_i + b \geq 1 \quad (4)$$

$$y = -1 \text{ için } w \times x_i + b \leq -1 \quad (5)$$

Yapay Sinir Ağları (Artificial Neural Networks, ANN) karmaşık ortamlarda tahmin etme ve tahmin için yararlı olan matematiksel modelleme araçlarıdır [23]. ANN'nin temel bileşeni nörondur [24].

$x_1, x_2, x_3, \dots, x_n$  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 (Denklem 6) [25].

$$Net\ Veri = \sum x_i w_i \quad (6)$$

ANN, 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. Bundan sonra çıktı katmanı sonucu gönderir [25].

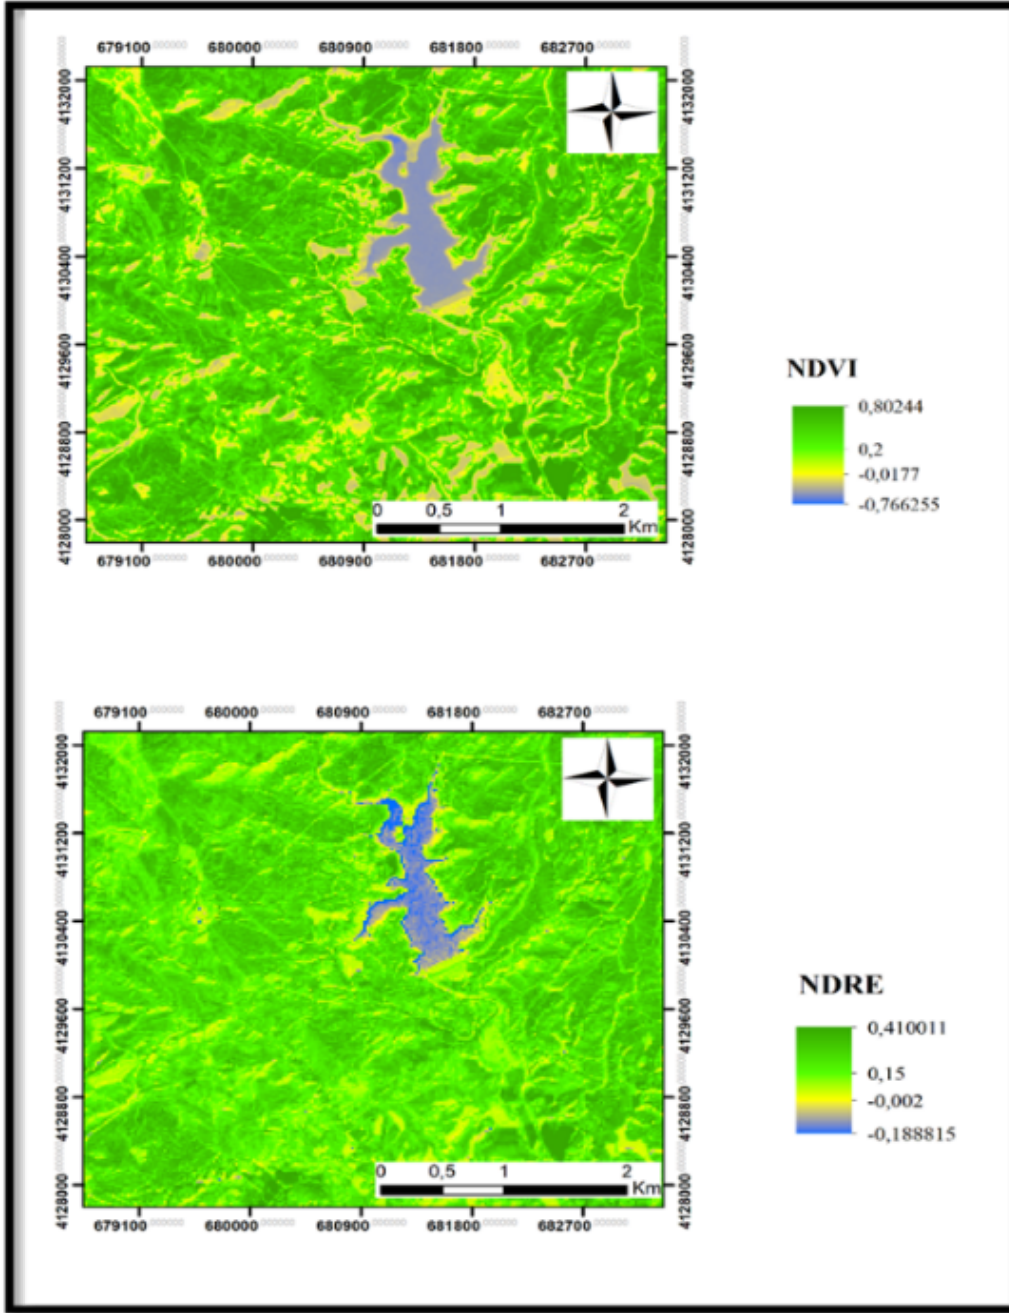
Otsu yöntemi, bir görüntü için gri seviyeleri kullanarak sınıf içi varyanslar ile eşik değerini otomatik olarak belirleyen bir tekniktir [26]. Çalışmada NDRE ve NDVI uygulanmış görüntülerin sınıflarının eşik değerlerinin tespit edilmesinde kullanılmıştır.

10 metre çözünürlüğe sahip kırmızı ve NIR bantları kullanılarak NDVI bant oranlama tekniği ve 20 metre çözünürlüğe sahip kırmızı kenar bandı (Bant 5) ve 20 metreye yeniden örneklenmiş NIR kullanılarak NDRE uygulanmıştır (Şekil 3).

10 metre çözünürlüğe sahip kırmızı, yeşil ve mavi bantlar kullanılarak, uygulanan SVM yönteminde, Kernel radyal tabanlı fonksiyon kullanılarak eşik değeri 0, gamma değeri 0,333 seçilmiştir. Üç sınıf oluşturulmuştur (Şekil 5). 10 metre çözünürlüğe sahip kırmızı, yeşil ve mavi bantlar kullanılarak, ANN yöntemi uygulanırken bir adet gizli katman kullanılmış ve 100 iterasyon ile sınıflama işlemi gerçekleştirilmiştir (Şekil 5). Çalışma alanında 100 adet kontrol noktası random olarak seçilmiştir (Şekil 6). Arazi üzerinde yapılan gözlemler ve Google Earth Engine [27] yazılımı kullanılarak oluşturulmuştur. Nokta sayısı literatürdeki çalışmalara göre tespit edilmiştir. Makineci ve Akosman [28] kontrollü sınıflandırma tekniklerinin doğruluk analizi için rastgele üretilmiş 100 nokta kullanmıştır. Çiçekli [29] nesne tabanlı sınıflama tekniğinin doğruluk analizi için arazi üzerinde 300 nokta üretilip, bu noktaların %30 unu test verisi olarak kullanmıştır.

### 3. Bulgular

Bant 4 ve Bant 8 kullanılarak elde edilen NDVI, Bant 5 ve Bant 8 kullanılarak elde edilen NDRE haritaları Şekil 3'te sunulmuştur.

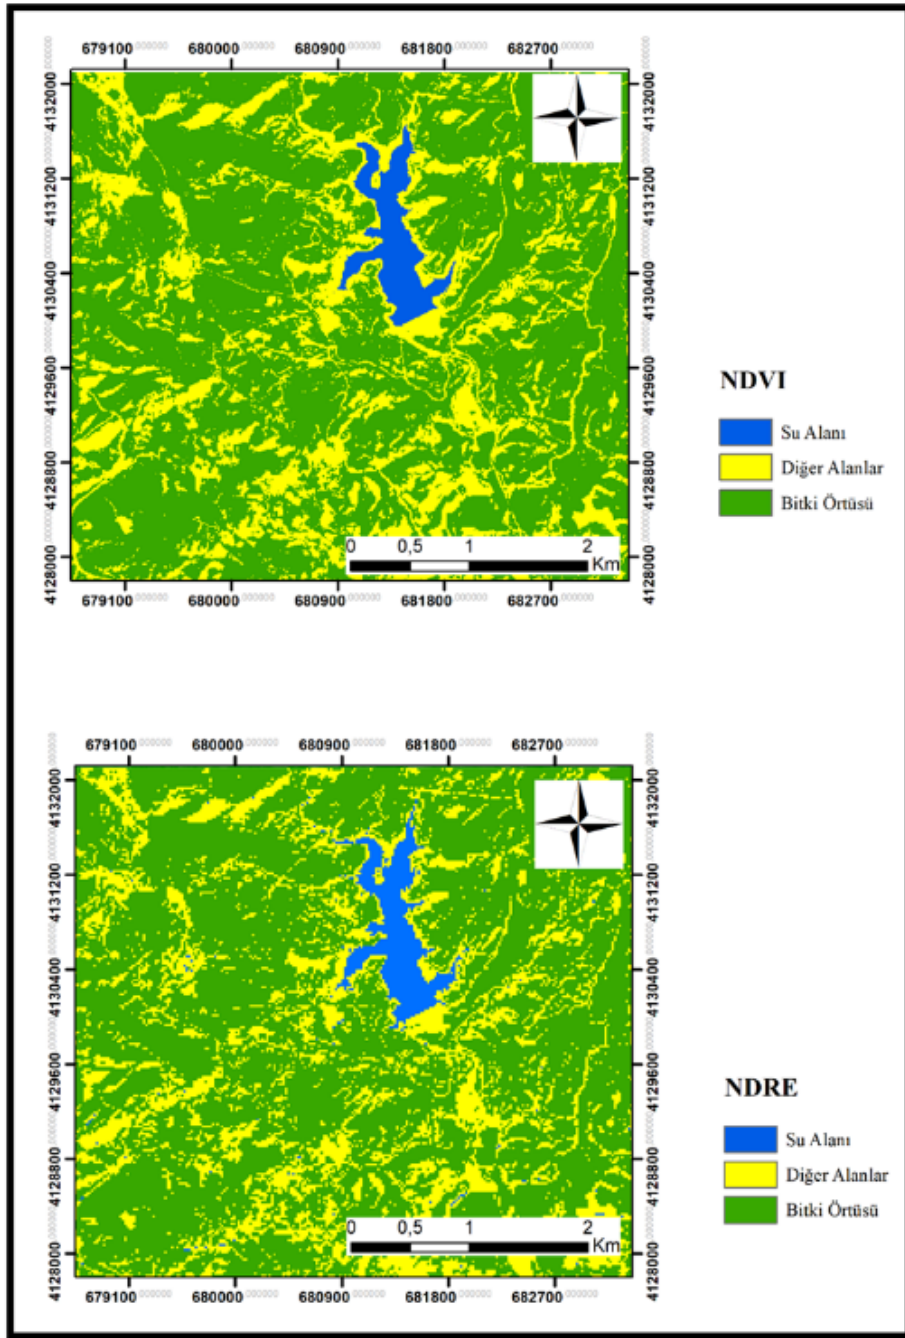


Şekil 3. NDVI görüntüsü ve NDRE görüntüsü.

NDVI haritasında en düşük değer -0,766255, en yüksek değer 0,80244 olmuştur. NDVI değerleri, 0,80244' e yaklaştıkça yoğun ve sağlıklı bitki örtüsünü temsil etmektedir. NDRE haritasında en düşük değer -0,188815, en yüksek değer 0,410011 olmuştur. NDRE değerleri, 0,410011' e yaklaştıkça yoğun ve sağlıklı bitki örtüsünü temsil etmektedir (Şekil 3).

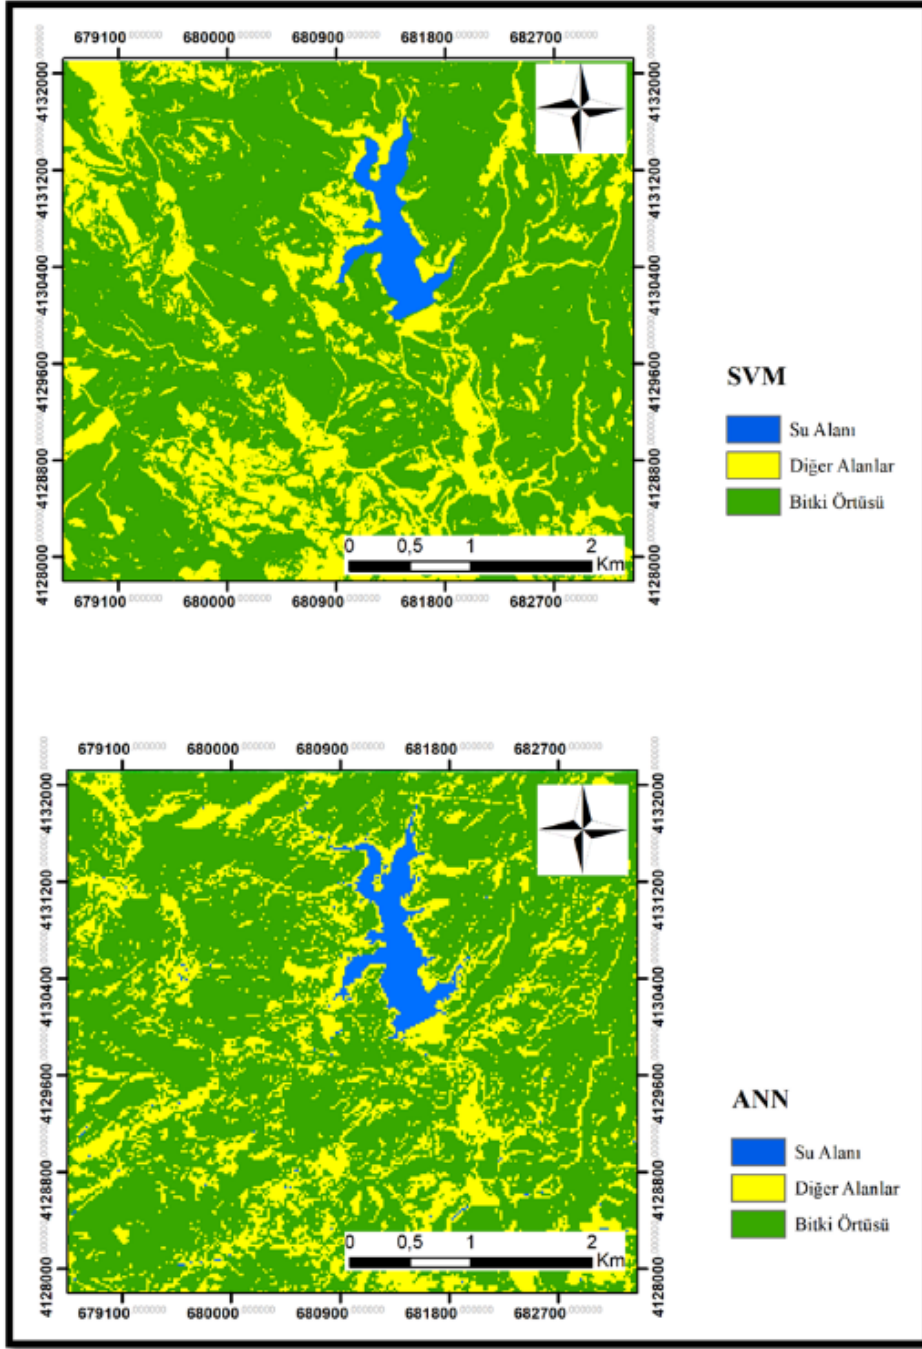
NDVI ve NDRE sınıflarını belirlemek için eşik değerleri Otsu yöntemi ile tespit edilmiştir. Eşik değerleri NDVI yöntemi için -0,0177 ve 0,2; NDRE yöntemi için -0,002 ve 0,15 olarak belirlenerek NDVI ve NDRE sınıfları oluşturulmuştur (Şekil 4).





Şekil 4. NDVI ve NDRE sınıfları.

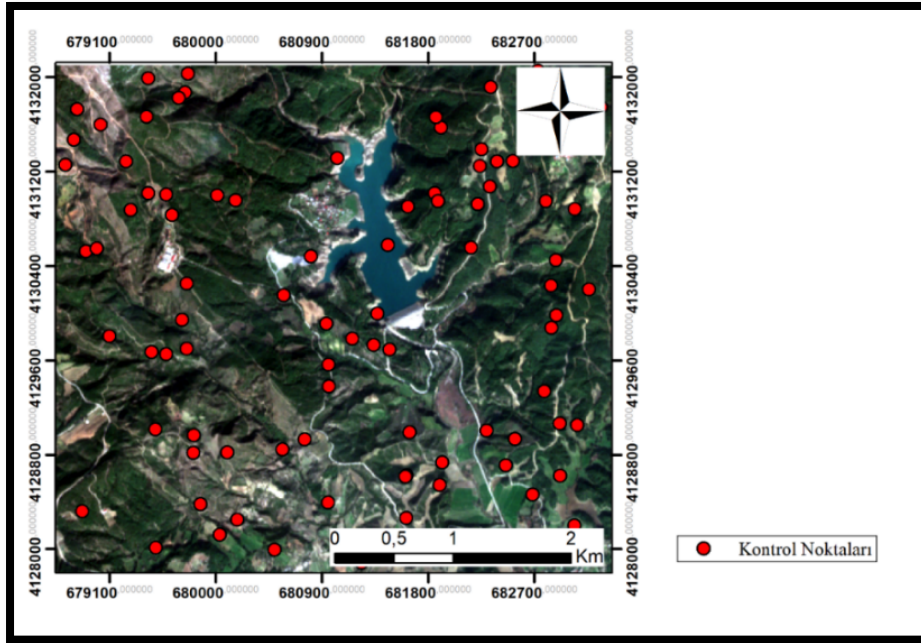
Bant 2, Bant 3 ve Bant 4 kullanılarak ANN ve SVM uygulanmış görüntüler Şekil 5’te sunulmuştur.



Şekil 5. ANN ve SVM sınıfları.

100 adet kontrol noktası ile oluşturulmuş hata matrisleri üzerinden yapılan doğruluk analizleri Tablo 2’de sunulmuştur.





Şekil 6. Kontrol noktaları.

Tablo 2. Genel doğruluklar ve kappa değerleri.


Yöntem	Genel doğruluk	Kappa değeri
NDVI	%81	0,51
NDRE	%84	0,61
ANN	%88	0,71
SVM	%89	0,73

Uygulanan bant oranlama teknikleri ve piksel tabanlı sınıflama yöntemlerinin hesaplanan genel doğrulukları incelendiğinde, en yüksek doğruluğu SVM yönteminin sağladığı görülmektedir. Hesaplanan kappa değerleri, genel doğruluk değerleri ile uyumludur. Her bir yöntem için hesaplanan sınıfların piksel sayıları ve alanlar Tablo 3'te sunulmuştur.

Tablo 3. Sınıfların piksel sayıları ve alanlar.

Yöntem	Su Alanı		Boş Alanlar ve Yerleşim Alanları		Bitki Örtüsü	
	Piksel Sayısı	Alan (km <sup>2</sup> )	Piksel Sayısı	Alan (km <sup>2</sup> )	Piksel Sayısı	Alan (km <sup>2</sup> )
NDVI	5411	0,54	60292	6,03	154689	15,4
NDRE	1598	0,6	15612	6,2	38125	15,2
ANN	5470	0,54	69890	6,98	145037	14,5
SVM	4949	0,49	58431	5,84	157017	15,7

Doğruluk analizi için kullanılan 100 adet kontrol noktasının dağılım grafiği ve lineer regresyon doğrusu üretilmiştir. NDVI ve NDRE değerleri birbiri ile uyumlu olup korelasyon katsayısı (R) 0,837'dir (Şekil 7).

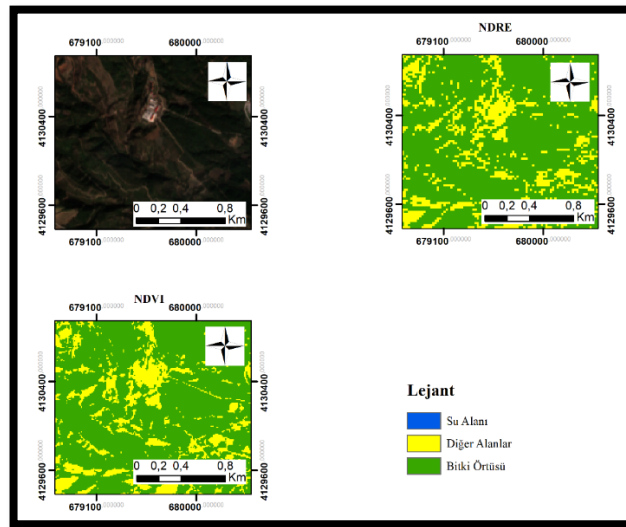


Şekil 7. Kontrol noktalarının NDVI ve NDRE dağılım grafiği.

#### 4. Tartışma

NDRE, NDVI yönteminden farklı olarak kırmızı bant yerine Kırmızı kenar bandını kullanmakta olup, kırmızı kenar bandı bitkilerdeki klorofile karşı daha duyarlıdır. Bu nedenle NDRE yöntemi, NDVI yöntemine göre daha yüksek doğruluk vermiştir. Bu durum literatürdeki çalışmalarla uyum sağlamaktadır [6-10-11-12-13]. Çınar ve ark. Sentinel-2A uydu görüntülerine farklı bitki örtüsü indeksleri uygulayarak, bitkiler üzerindeki hastalıkları araştırmıştır. NDRE yönteminin %89 ile en yüksek doğruluğu verdiğini, NDVI ve PSRI yönteminin yüksek doğruluk sağlayanlar yöntemler olduğunu tespit etmiştir [12]. Zhang ve ark. pirinç ekili alanlarda erken ve orta büyüme evresinde verim tahmini çalışmasında NDRE, NDVI indekslerinin kullanımını karşılaştırmıştır ve NDRE yönteminin, diğer yöntemlere göre daha uygun olduğunu tespit etmiştir [30]. Barboza ve ark. fasulye bitkisi yetiştirme aşamalarında yeşil biyokütle için NDVI ve NDRE indekslerini kullanmış, NDVI yönteminin NDRE yönteminden daha yüksek doğruluk verdiğini tespit etmiştir [31]. Literatürde NDVI tekniğinin, NDRE tekniğinden daha yüksek doğruluk verdiği çalışmalar da bulunmaktadır [31]. Bu durum çalışma alanına uygun yöntem seçiminin önemini göstermekte olup, çalışma alanı için NDRE yöntemi, NDVI yöntemine göre daha uygundur.

Kullanılan tüm teknikler yüksek doğruluk sağlamasına rağmen çalışmada kullanılan kırmızı kenar bandı, 20 metre çözünürlüğe sahip olduğu için, NDRE yöntemi kullanılırken NIR bandı da 20 metreye yeniden örneklenecek kullanılmıştır. NDRE görüntüsünün 20 metre çözünürlükle üretilmiş olması bir dezavantajdır. Bu durum çalışma alanı içerisinde bitki örtüsü içeren ve bitki örtüsünden yoksun alanları bir arada bulandıran bir alan seçilerek Şekil 8’de açıklanmıştır. NDRE tekniği, NDVI yönteminden daha yüksek doğruluk sağlamış olmasına rağmen, NDRE görüntüsünün daha düşük bir çözünürlüğe sahip olduğu ve çalışma alanına dair detayları daha az bilgi verdiği görülmektedir.



Şekil 8. Çalışma alanı içerisinde NDVI ve NDRE örneği.

ANN ve SVM piksel tabanlı sınıflama yöntemleri literatürde yer alan çalışmalarda olduğu gibi NDVI ve NDRE bant oranlama tekniklerine göre daha yüksek doğruluk sağlamıştır [6]. SVM ve ANN piksel tabanlı sınıflandırma yöntemlerinin doğrulukları birbirine çok yakındır. En yüksek doğruluğu SVM yöntemi sağlamıştır. Literatürde SVM yönteminin ANN yönteminden daha yüksek doğruluk sağladığı [3-8] çalışmalar yer almaktadır. Khurana ve Gupta, Hindistan'da Sentinel-2A görüntülerine SVM, ANN ve MLC piksel tabanlı sınıflama yöntemleri uygulayarak arazi örtüsünü araştırmıştır. En yüksek doğruluğu SVM yöntemin sağladığı belirlenmiştir. SVM yöntemi %98,1 doğruluk, ANN yöntemi %95,6 ve MLC yöntemi %96,5 genel doğruluk sağlamıştır [32]. Soni ve ark., Delhi bölgesinde Sentinel-2 görüntülerine SVM, ANN ve MLC uygulayarak yerleşim alanlarında arazi örtüsünü tespit etmiş ve yöntemlerin doğruluğunu araştırmıştır. Tüm yöntemlerin %90'ın üzerinde genel doğrulukla arazi örtüsünü tespit ettiğini ve en yüksek doğruluğu %98,05 ile SVM yönteminin sağladığını tespit etmiştir [33]. Ayrıca literatürde ANN yönteminin SVM yönteminden daha yüksek doğruluk sağladığı [9] çalışmalar da yer almaktadır. Bu durum çalışma alanına uygun yöntem seçiminin gerekliliğini ortaya çıkarmaktadır. Çalışma alanı için en uygun yöntemin SVM kontrollü sınıflama yöntemi olduğu tespit edilmiştir.

Nergizlik Baraj Gölü, bölgedeki sulama faaliyetleri açısından önemli bir konumda olduğundan düzenli olarak gözlemlenmesi gereken bir su kaynağıdır. Seyhan Sağ Sahil Sulama Birliği, Nergizlik Barajı sulamasında temizlik çalışmalarını gerçekleştirmektedir [34]. Baraj Gölünün su seviyesinin tespiti [35] ve barajın jeoteknik olarak incelenmesi [36] literatürdeki çalışmalara konu olmuştur. Ancak literatürde baraj gölünün çevresine ait Sentinel-2 uydu görüntülerini kullanılarak LULUCF tespit eden bir çalışma bulunmamaktadır. Bu çalışma ile bölgeye ait LULUCF tespit etmek ve ilerleyen zamanlarda LULUCF değişiminin analizini gerçekleştirmek için en uygun yöntemin SVM yöntemi olduğu sonucuna ulaşılmıştır.

## 5. Sonuç

Bu çalışmada, Sentinel-2B uydu verileri kullanılarak Nergizlik Baraj Gölü ve çevresinde LULUCF'nin belirlenmesi için piksel tabanlı (SVM, ANN) sınıflandırma yöntemleri ve NDVI, NDRE bant oranlama teknikleri kullanılmış, bu yöntemlerin doğruluk analizi yapılmıştır.

SVM ve ANN sonuçları birbirine yakın çıkmış olup, en yüksek doğruluğu SVM piksel tabanlı sınıflama tekniği olmuştur. NDVI yöntemi beklenen doğruluğu karşılamış ancak düşük doğruluğu sağlayan teknik olmuştur. NDRE klorofile daha duyarlı olduğu için NDVI yöntemine göre daha yüksek doğruluk sağlamıştır.

Doğruluk sonuçları göz önüne alındığında, tüm teknikler tatmin edici sonuçlar sunmaktadır. Elde edilen sonuçlar, su alanları ve çevresinde LULUCF çalışmalarında hem piksel tabanlı sınıflandırma yöntemlerinin hem de bant oranlama yöntemlerinin yüksek doğruluk sağladığını, çalışma alanına en uygun LULUCF belirleme yönteminin SVM piksel tabanlı sınıflama yöntemi olduğunu göstermektedir.

Sonraki çalışmalarda çalışma alanına ait arazi örtüsünün mevsimsel değişimin incelenmesi hedeflenmektedir.

## Teşekkür

S.Y.O., fikir sahibi olup deneyleri gerçekleştirdi, sonuçları yorumladı ve makaleyi yazdı.

## Kaynaklar

- [1] Pakhale GK, Gupta PK. Comparison of advanced pixel based (ANN and SVM) and object-oriented classification approaches using landsat-7 Etm+ data. *Int J Eng Technol* 2010; 2(4): 245-251.
- [2] Deilmai BR, Kanniah KD, Rasib AW, Ariffin A. Comparison of pixel-based and artificial neural networks classification methods for detecting forest cover changes in Malaysia. In *IOP Conference Series: Earth and Environmental Science* 2014.
- [3] Pujari D, Yakkundimath R, Byadgi AS. SVM and ANN based classification of plant diseases using feature reduction technique. *Int J Interact Multimed Artif Intell* 2016;3(7): 6-14.
- [4] Kuc G, Chormański J. Sentinel-2 imagery for mapping and monitoring imperviousness in urban areas. *Int Arch Photogramm Remote Sens Spat Inf Sci* 2019; 42: 43-47.
- [5] Özdarıcı OA. Yüksek Mekânsal çözünürlüklü uydu görüntülerinden otomatik ağaç tespiti: yeni bir yaklaşım. 5. Uzaktan Algılama-CBS Sempozyumu, İstanbul, Türkiye, 2014.
- [6] Ustuner M, Sanli FB., Abdikan S, Esetlili MT, Kurucu Y. Crop type classification using vegetation indices of rapideye imagery. *Int Arch Photogramm Remote Sens Spat Inf Sci* 2014; 40: 195-198.
- [7] Doğan S, Buğday E. Modeling of temporal and spatial changes of land cover and land use by artificial neural networks: Kastamonu sample. *Bartın Orman Fak Derg* 2023; 20(3): 653-663.
- [8] Yuh YG, Tracz W, Matthews HD, Turner SE. Application of machine learning approaches for land cover monitoring in northern Cameroon. *Ecol Inf* 2023; 74: 1-15.
- [9] Çiçekli SY, Sekertekin A, Arslan N, Donmez C. Comparison of pixel and object-based classification methods in Wetlands using sentinel-2 Data. In *3rd International Mediterranean Science and Engineering Congress*, 2018. pp. 298-302.

- [10] Boiarskii B, Hasegawa, H. Comparison of NDVI and NDRE indices to detect differences in vegetation and chlorophyll content. *J Mech Contin Math Sci* 2019; 4: 20-29.
- [11] Naguib NS, Daliman S. Analysis of NDVI and NDRE indices using satellite images for crop identification at Kelantan. In *IOP Conference Series: Earth and Environmental Science* 2022, 1102: 1-7.
- [12] Çınar T, Beram RC, Aydın A, Akyol S, Tashigul N, Lehtijärvi HT, Woodward S. Detection of heterobasidion root rot on pinus brutia ten. using different vegetation indices generated from Sentinel-2 A satellite imagery. *J Indian Soc Remote Sens* 2024; 52: 1805–1817.
- [13] Borgogno-Mondino E, Farbo A, Novello V and Palma LD. A fast regression-based approach to map water status of pomegranate orchards with Sentinel 2 data. *Horticulturae* 2022; 8(9); 759:1-17.
- [14] ESA. <https://scihub.copernicus.eu/dhus/#/home/> Accessed 20 March 2024.
- [15] T.C. Milli Savunma Bakanlığı Harita Genel Müdürlüğü. <https://www.harita.gov.tr/urunler/> Accessed 07 June 2024.
- [16] Bayram B, Ustuner M. Yeniden Örneklemenin Sınıflandırma Sonucuna Etkisi. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu*, 2013. pp. 1-4.
- [17] Pettorelli N, Ryan, S, Mueller T, Bunnefeld N, Jędrzejewska B, Lima M, Kausrud K. The normalized difference vegetation index (NDVI): unforeseen successes in animal ecology. *Clim Res* 2011; 46(1): 15-27.
- [18] Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC. Monitoring the vernal advancements and retrogradation (greenwave effect) of nature vegetation; *NASA/GSFC Final Report*; NASA: Greenbelt, MD, USA, 1974.
- [19] Tucker CJ. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens Environ* 1979; 8(2): 127-150.
- [20] Barnes, EM, Clarke TR, Richards SE, Colaizzi PD, Haberland J, Kostrzewski M, Waller P, Choi C, Riley E, Thompson T, Lascano RJ, Li H, Moran MS. Coincident Detection of Crop Water Stress, Nitrogen Status and Canopy Density Using Ground Based Multi- Spectral Data. *5th International Conference on Precision Agriculture*, Bloomington, MN, USA, 2000
- [21] Gündoğdu KS, Bantchina BB. Landsat uydu görüntülerinden NDVI değer dağılımının parsel bazlı değerlendirilmesi, Uludağ Üniversitesi Ziraat Fakültesi çiftlik arazisi örneği. *Bursa Uludağ Üniv Ziraat Fak Derg* 2018, 32(2): 45-53.
- [22] Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: A review. *ISPRS J Photogramm Remote Sens* 2011; 66: 247–259.
- [23] Hamed MM, Khalafallah MG, Hassanien EA. Prediction of wastewater treatment plant performance using artificial neural networks. *Environ Modell Software* 2004; 19(10): 919-928.
- [24] Nasr MS, Moustafa MA, A.-Seif H, El Kobrosy G. Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT. *Alexandria Eng J* 2012; 51(1):37-43.
- [25] Haykin S. *Neural Networks: A Comprehensive Foundation*, Macmillan College Publishing Company, 1994.
- [26] Otsu N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Trans. Syst. Man. Cybern* 1979; 9: 62–66.
- [27] Google LLC. Google Earth Engine (Computer software) <https://earthengine.google.com/> Accessed 06.05.2024.
- [28] Makineci HB, Akosman EN. Sentinel-2A verileriyle Trabzon İli 2019-2020 yılları arasında ortaya çıkan sınıflandırma farklarının çeşitli algoritmalarla değerlendirilmesi. *Türkiye Uzaktan Algılama Derg* 2023; 5(2): 78–88.
- [29] Çiçekli SY. Otomatize edilmiş nesne tabanlı arazi örtüsü sınıflandırma modeli: Aşağı Seyhan Ovası örneği. *Doktora Tezi*, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, 2022.
- [30] Zhang K, Ge X, Shen P, Li W, Liu X, Cao Q, Zhu Y, Cao W, Tian, Y. Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages. *Remote Sens* 2019; 11(4); 387: 1-24.
- [31] Barboza TOC, Ardiguier M, Souza GFC, Ferraz MAJ, Gaudencio JRF, Santos AFD. Performance of vegetation indices to estimate green biomass accumulation in Common Bean. *AgriEngineering* 2023; 5(2):840-854.
- [32] Khurana Y, Gupta S. LCLU Classification using SVM, MLC and ANN of multispectral imagery from Sentinel-2. *Int J Eng Res Tech (IJERT)* 2022;11(10):1-8.
- [33] Soni PK, Rajpal N, Mehta R, Mishra VK. Urban land cover and land use classification using multispectral sentinel-2 imagery. *Multimedia Tools Appl* 2022; 81(26): 36853-36867.
- [34] T.C. Seyhan Sağ Sahil Sulama Birliği. <https://seyhansagsahilsulama.gov.tr/proje/karaisali-nergizlik-baraji-sulamasinda-temizlik-calismalari/> Accessed 05 October 2024.
- [35] Akgül MA, Çetin M. Baraj gölü su kotunun Landsat 8 uydu görüntüleri kullanılarak tahmin edilmesi. *DÜMF Mühendislik Derg* 2018; 9(1): 493-502.
- [36] Kılıç M, Çetin H. Nergizlik Barajı (Adana) kil çekirdek malzemesinin jeoteknik incelemesi. *Ç.Ü Fen ve Mühendislik Bilimleri Derg* 2011; 26(3): 118-128.