

## Kıyı Çizgisinin Makine Öğrenmesi Tabanlı Mean-Shift, Rastgele Orman ve Destek Vektör Makinaları ile Belirlenmesi

Şeyma AKÇA \*<sup>1</sup> ORCID 0000-0002-7888-5078

Fusun BALIK ŞANLI<sup>2</sup> ORCID 0000-0003-1243-8299

<sup>1</sup>Harran Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Şanlıurfa

<sup>2</sup>Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul

Geliş tarihi: 01.03.2022 Kabul tarihi: 23.09.2022

Atıf şekli/ How to cite: AKÇA, Ş., BALIK ŞANLI, F., (2022). Kıyı Çizgisinin Makine Öğrenmesi Tabanlı Mean-Shift, Rastgele Orman ve Destek Vektör Makinaları ile Belirlenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(3), 835-842.

### Öz

Kıyıları kara ve deniz sınırını oluşturan, belirli bir canlı ekosistemini ihtiva eden alanlardır. Suların iklim değişimine bağlı olarak çekilmesi veya yükselmesi, gelgit hareketleri, tropik ekosistemlerde hava olaylarına bağlı olarak meydana gelen fırtına, hortum, kasırga vb. iklim olaylarında, deniz alanlarının karalardan ayrıldığı kıyı çizgisinin belirlenmesi önem arz etmektedir. Bu çalışma kapsamında Sentinel-2A uzaktan algılama görüntüsü üzerinde, makine öğrenmesi tabanlı mean-shift, rastgele orman (RO) ve destek vektör makinaları (DVM) yöntemleri uygulanmış olup, bölütleme sonrası sonuç görüntüleri doğruluk ve IoU metrikleri ile değerlendirilmiştir. Genel doğruluklar, mean-shift, rastgele orman ve destek vektör makinaları için sırasıyla %97.23, %99.15 ve %98.68 bulunmuştur.

**Anahtar Kelimeler:** Kıyı çizgisi, Rastgele orman, Mean-shift, Destek vektör makinaları, Bölütleme

### Machine Learning Based Segmentation of Shoreline Using Mean-Shift, Random Forest and Support Vector Machine

#### Abstract

The coast is an area that forms the boundary between land and sea and contains a certain ecosystem of life. To determine the coastline where sea areas are separated from the land in climatic events such as storms, tornadoes, hurricanes, which occur due to the withdrawal or rise of waters due to climate change, tidal movements, weather events in tropical ecosystems. In this study, machine learning-based mean-shift, random forest (RO), and support vector machines (SVM) methods were used on the Sentinel-2A satellite image, and the results were evaluated by calculating overall accuracy and using IOU metrics. The overall accuracies are 97.23%, 99.15%, and 98.68% for mean-shift, random forest, and support vector machines, respectively.

**Keywords:** Shoreline, Random forest, Mean-shift, Support vector machine, segmentation

\*Sorumlu yazar (Corresponding author): Şeyma AKÇA, [seymakca@harran.edu.tr](mailto:seymakca@harran.edu.tr)

## 1. GİRİŞ

Kıyılar kara ve deniz sınırını oluşturan, belirli bir canlı ekosisteminin içerisinde yaşamasına olanak sağlayan alanlardır. Kıyılar okyanus ve denizlerin biriktirme ve aşındırma faaliyetleri sonucu oluşur [1]. Suların iklim değişimine bağlı olarak çekilmesi veya yükselmesi, gelgit hareketleri, tropik ekosistemlerde hava olaylarına bağlı olarak meydana gelen fırtına, hortum, kasırga vb. iklim olaylarında, denizlerin karalardan ayrıldığı kıyı çizgisi alanlarının belirlenmesi, izlenmesi, yönetimi ve sürdürülmesi için sinoptik görüş sunan uzaktan algılama sistemleri ile geniş alanlarının takibi, diğer yersel ölçümlere nazaran daha etkili, hızlı ve düşük maliyetlidir.

Kıyı çizgisi ülkemiz için 8333 kilometre uzunluğundadır [2]. Geniş bir sınır ihtiva eden kıyı sınırlarımızın yıllar içerisindeki doğal ve antropojenik süreçlere bağlı olarak değişiminin gözlenmesi için yapay zeka çalışmalarının bir uygulama alanı olan makine öğrenmesi yöntemleri ile doğrudan belirlenebilmektedir. Uydu görüntüleri üzerinde yapılan görüntü segmentasyonu diğer bir deyişle bölütleme, görüntü analizi işleminde benzer gri seviye değerlerine sahip görüntü piksellerin homojen olarak gruplandırılmasıdır. Genel olarak, görüntü bölütlemesi için kullanılan yöntemler kontrollü veya kontrolsüz olmak üzere iki şekilde sınıflandırılır. Kümeleme tabanlı kontrolsüz bölütleme yöntemlerinde piksel gruplama işlemi, küme merkezlerinin güncellenmesi bitinceye kadar devam eder. Örneğin, K-Means veya makale kapsamında uygulanan Mean-Shift gibi yöntemlerde durum böyledir. Kontrollü öğrenme tabanlı makine öğrenmesi yöntemlerine ise en çok benzerlik (EÇB), rastgele orman (RO) ve destek vektör makinaları (DVM) örnek verilebilir.

Bu çalışma kapsamında, uzaktan algılama verileri ile kıyı çizgisinin belirlenmesi için makine öğrenmesi tabanlı, mean-shift, rastgele orman (RO) ve destek vektör makinaları (DVM) yöntemleri kullanılarak, bölütleme sonuçları

doğruluk metrikleri ve kesişim üzerinden birliklilik (IOU) metrikleri ile değerlendirilmiştir.

## 2. ÖNCEKİ ÇALIŞMALAR

Kıyı çizgisi belirlenmesi üzerine daha önceki yapılan çalışmalar incelendiğinde; Şatıroğlu ve arkadaşları (2015), İstanbul'un Anadolu Feneri ve Ağva dahil olmak üzere 1990-2005 yılları arasında kıyılarda meydana gelen değişimi Landsat MSS ve Landsat TM uydu görüntüleri üzerinde gerçekleştirilen ISODATA ve EÇB yöntemi ile sınıflandırmıştır. Çalışma sonucunda 1990-2005 yılları arasındaki değişim tarım alanları için %63,9, yerleşim %60,7, çayır %50,8 azalış gösterirken; ağaç %39,1 ve boş alan %18,2'lik bir artış göstermiştir. Ünel ve arkadaşları (2019), Aydınlar Göleti'nin 2015-2019 yılları arasındaki kıyı değişimini ortofoto haritalar üzerinde inceleyip göl alanının 8713.83 m<sup>2</sup> büyüdüğünü belirtmişlerdir [3]. Erdem ve arkadaşları (2018), Landsat-8 görüntüsü üzerinde İstanbul'un belirli bölgesi için rastgele orman yöntemi ile kıyı çizgisini belirlemek için farklı spektral kombinasyonlar üzerinde 14,93 ve 14,85 karesel ortalama hata ile belirlemişlerdir [4]. Çoban ve arkadaşları (2019), Batum/Çoruh Deltasında HES'lerin işletilmesinden sonraki dönem olan 1985-2019 yılları arasındaki 11 uzunluğundaki km kıyı değişimi için ASTER GDEM verisi üzerinde ürettikleri sayısal yükseklik modeli ile kıyı çizgisinin kara yönünde 238 m'ye kadar gerilediğini gözlemlemişlerdir [5]. Aykut (2019), İHA ile elde edilen kıyı görüntüleri üzerinde 10 metre aralıklarla enine kesitler oluşturup GNSS ile kıyı boyunca aldığı koordinatlar arasında yapılan hesaplama ile konum doğruluğunu 1.068 m olarak belirlemiştir [6]. Kılar ve arkadaşları (2019), Mersin Göksu deltasının kıyı değişiminin 25 ve 50 yıl sonraki konumlarını 1984-2017 yılları arasındaki Landsat görüntüleri üzerinde bant oranlaması yaparak, elde edilen kıyı çizgilerini DSAS (Digital Shoreline Analysis Tool) aracı ile kıyı değişim değerlerini dikkate alarak ileriye yönelik tahmin gerçekleştirmişlerdir. Sonuç olarak 25 yıl için kıyı çizgisinin ortalama 114 m ve 50 yıl

sonra ortalama 223 m gerileme olacağı aşınma alanları için elde edilirken birikme alanları için 25 yıl sonra ortalama 119 m ve 50 yıl sonra 236 m olacağı öngörülmüştür [7]. Kıyı çizgisinin belirlenmesinde yapılmış uluslararası çalışmalara bakıldığında; Di ve arkadaşları (2003) yüksek çözünürlüğe sahip IKONOS uydu görüntüsü üzerinde PAN bandı da kullanarak mean-shift yöntemi kıyı çizgisinin segmentasyonunu gerçekleştirmişlerdir [17]. Bamdadinejad ve arkadaşları (2021), 1998-2017 yılları arasındaki Landsat görüntüleri kullanılarak DVM ve EÇB yöntemleri ile kıyı çizgisini çıkarmışlardır [18]. Billa ve arkadaşları (2011), Malezya bölgesine ait Radarsat-1 SAR görüntüsü üzerinde yarı otomatik olarak kıyı çizgisinin çıkarımı gerçekleştirmişlerdir [19]. Rishikeshan ve arkadaşları (2017), Cartosat 1-2, LISS IV ve Landsat 8 görüntüleri kullanarak geliştikleri morfolojik tabanlı matematiksel yaklaşım ile kıyı çizgisinin çıkarımını gerçekleştirmişlerdir [20]. Kafrawy ve arkadaşları (2017), kıyı gözleme için Landsat 8 görüntüsü üzerinde eşikleme, bant oranlama ve sınıflandırma işlemleri gerçekleştirerek normalize fark bitki indeksi ve normalize fark su indeksini uygulamışlardır. Elde edilen kıyı çizgisinin doğrulamasını yüksek çözünürlükle Pleiades B1 görüntüsü ile gerçekleştirmişlerdir. Uyguladıkları yöntemler %84-%94 arasında bir doğruluk üretmiştir [21].

### 3. MATERYAL VE YÖNTEM

#### 3.1. Materyal

Uygulama görüntüsü Copernicus (ESA) tarafından ücretsiz olarak sağlanan 22/04/2021 tarihli Sentinel-2A uydu görüntüsüdür. Uygulama ile kara ve deniz sınırlarının ayrılıp kıyı çizgisinin tespiti amaçlanmıştır. Orijinal olarak 12 banda sahip uydu görüntüsünün 10 metre konumsal çözünürlüğe sahip kırmızı, yeşil, mavi ve NIR bantları birleştirilip uygulama görüntüsü 4 bantlı bir koleksiyon haline getirilmiştir (Çizelge 1). 798x798 piksel boyutlarında olacak şekilde, çalışma bölgesi İstanbul olarak belirlenmiştir.

Uygulamalar MATLAB ortamında gerçekleştirilmiştir.

**Çizelge 1.** Sentinel- 2A bant bilgileri [8]

Bant	Spektral Alan	Dalgaboyu Aralığı (nm)	Çözünürlük (m)
B1	Kıyı Aerosol	0.443	60
B2*	Mavi	0.490	10
B3*	Yeşil	0.560	10
B4*	Kırmızı	0.665	10
B5	Vejetasyon Kırmızı Köşe	0.705	20
B6	Vejetasyon Kırmızı Köşe	0.740	20
B7	Vejetasyon Kırmızı Köşe	0.783	20
B8*	Yakın Kırmızı ötesi (NIR)	0.842	10
B8A	Vejetasyon Kırmızı Köşe	0.865	20

\*Çalışma kapsamında seçilen bantlar

#### 3.2. Mean-Shift

Mean-Shift, obje tabanlı kontrolsüz bir görüntü segmentasyon yöntemidir. 1975 yılında Fukunaga ve Hostetler tarafından ortaya atılmıştır.  $K(x)$  yoğunluk tahmin kerneli olmak üzere,  $d$  boyutlu bir öklit uzayında  $R^d$  rastgele dağılmış  $n$  nokta içinde  $x(i)$  ( $i=1,2,\dots,n$ )  $x$ 'i hesaplamak için öncelikle kernel yoğunluk fonksiyonu hesaplanır:

$$f(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x-x_i}{k}\right) \quad (1)$$

Kernelin tahmin kalitesi, yoğunluk ve tahmin edilen yoğunluk arasındaki karesel hatanın ortalaması ile ölçülür.  $f(x)$  yoğunluk fonksiyonu ile tanımlanan nitelik uzayında öncelikle olarak

modlar belirlenir. Modlar, gradyanların sıfır oldukları noktalarda vardır. Bu sonuçlara bakarak mean-shift ile bu değerler aranır.

$$G(x) = c_{g,d} g(|x|^2) \quad (2)$$

$$m_{h,G}(x) = \frac{1}{2} h^2 c \frac{\nabla f_{h,K}(x)}{f_{h,G}(x)} \quad (3)$$

Ortalama kayma prosedürü ardışık olarak aşağıdaki işlemlerin yapılması ile gerçekleşir:

- 1)  $m_{h,G}(x)$  ortalama kayma vektörünün hesaplanması
- 2) Kernel  $G(x)$ 'in ortalama kayma vektörü ile tekrar hesaplanması

Görüntü üzerinde mean-shift yöntemini uygulamak için görüntüye ait RGB değerleri  $L*u*v$  renk uzayına çevrilir [9]. Mean-shift, veri kümesi üzerindeki veri dağılımının en yüksek olduğu yeri bulmayı sağlar. Yani elinizdeki bir görüntü ve devam eden görüntü üzerinde (next frame), belirlenen bir alan içerisinde yer alan tepe noktalarının belirlemesi sürecidir. Belirlenen tepe noktaları, takip edilmek istenilen obje olacaktır. Oldukça basit, hızlı ve işlevsel bir yöntemdir.

### 3.3. Rastgele Orman

Rastgele orman yöntemi, 2001 yılında Leo Breiman tarafından geliştirilmiştir. Rastgele orman yöntemi oluşturduğu düğümler üzerinde, rastgele seçilen değişkenler arasındaki en iyi değeri kullanarak, her bir düğüm için yeniden dallara ayırır. Özellikler rastgele seçilerek ağaçlar geliştirilir. Ağaçlar, geliştirildikten sonra budama işlemi yapılmaz. Yöntemi uygulamak için iki parametre gereklidir. Bu parametreler, en iyi bölünmeyi gerçekleştirmek için kullanılan değişken sayısı (m) yani görüntü için bant sayısı ve geliştirilecek ağaç sayısı N, diğer bir ifade ile görüntü boyutudur. GINI indeksine bağlı olarak sınıf homojenliği ölçülür ve örneğin görüntü sınıflandırma işleminde pikselin hangi sınıfa ait

olduğu GINI indeksindeki değere göre belirlenir [10].


$$\sum_{j \neq i} (f(B_i, P/|P|)) (f(B_j, P/|P|)) \quad (4)$$

Burada  $P$  veri setindeki eğitim verisini,  $B_i$  rastgele şekilde seçilen pikselin ait olduğu etiket sınıfı ve  $f(B_i, P/|P|)$ , seçilmiş olan örneğin  $B_i$  sınıfına ait olma olasılığıdır. GINI indeks değeri büyüdükçe sınıf heterojenliği artarken, GINI indeks değeri azaldıkça sınıf homojenliği artar.

### 3.4. Destek Vektör Makinaları

Vladimir Vapnik ve Alexey Chervonenkis tarafından 1963 yılında temelleri atılan Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir kontrollü öğrenme algoritmasıdır [11]. Çoğunlukla sınıflandırma için kullanılan destek vektör makineleri doğrusal olarak ayrılabilen ve doğrusal olarak ayrılamayan olmak üzere iki çeşittir. DVM’de ayrılacak iki sınıf arasında en uygun ayırt etme yüzeyi belirlenir. Bu yüzeye yakın en yakın vektörler, ‘destek vektörü’ olarak isimlendirilir. Ağırlık ve girdi değerleri vektör şeklinde ifade edebilirse, veriler hiper düzlem boyunca ayrılır. Birçok sınıflandırma problemi için doğrusal sınıflandırma yetersiz kalmaktadır. Verilerin özellikle çok boyutlu problemlerde dağılımı doğrusal olmadığından, veri sınıflandırması için kullanılacak olan hiper-düzlem de doğrusal olmayan yapıya sahip olmalıdır. Ayrıca, destek vektör makineleri “kernel based” yani çekirdek fonksiyonu tabanlı sınıflandırıcılar grubundadır. DVM’de çekirdek fonksiyonları çok boyutlu verileri ayırmak için kullanılır. Çekirdek fonksiyonu sayesinde öncelikle veriler dual uzay olarak nitelendirilen Lagrange uzayına aktarılması gerekir. Lagrange uzayının özelliği problemi daha yüksek boyutlu bir uzaya taşıyarak verilerin daha rahat ayrılmasını sağlamasıdır.

İki sınıf için sınıflandırma -1/+1 sınıf etiketleri ile ifade edilirse;  $X=\{x_i, y_i\}$  için  $x_i \in R_1$  ise  $y_i = +1$  ve  $x_i \in R_2$  ise  $y_i = -1$  olur.  $1/ \|w\|$  destek vektörlerinin en uygun hiper düzleme olan uzaklığını ifade eder.



Şekil 1. Çalışma bölgesi

Doğrusal olarak ayrılabilen destek vektörlerine ait Lagrange denklemi:

$$L_d = \frac{1}{2} w^2 \sum_{i=1}^N \delta_i y_i (w x_i + b) + \sum_{i=1}^N \delta_i \quad (5)$$

Doğrusal olarak ayrılamayan iki sınıfa ait destek vektör denklemi:

$$h(x) = \sum_{i=1}^N \delta_i y_i K(x_i, y_i) + b \quad (6)$$

$K(x_i, y_i)$  çekirdek fonksiyonlarını ifade etmektedir. DVM için kullanılan bazı çekirdek fonksiyonları: (5) lineer, (6) sigmoid, (7) polinomial ve (8) radial basis funtion (RBF) çekirdek (kernel) fonksiyonlarını ifade etmektedir.

$$K(x, y) = x.y \quad (7)$$

$$K(x, y) = \tanh(\gamma x.y) + b \quad (8)$$

$$K(x, y) = (1 + x.y)^d \quad (9)$$

$$K(x, y) = \exp(-\gamma x - y)^2 \quad K(x, y) = x.y \quad (10)$$

Çalışma kapsamında uygulanan DVM yöntemi için literatürde en çok kullanılan [12,13] RBF çekirdek fonksiyonu tercih edilmiştir.

#### 4. ÇALIŞMA BÖLGESİ VE DOĞRULUK ANALİZİ

Bölütleme sonrası doğruluk analizi, deniz için 403,415 ve kara için 233,389 nokta ile gerçekleştirilmiştir. Doğruluk, test görüntüsündeki etiket sınıfları ile yine sınıflandırma sonrası üretilen sonuç görüntüsü üzerinde bulunan değerler (sınıflar) arasında karşılaştırma yapılarak belirlenir. Bölütleme işlemine ait sınıflandırma ölçütleri Congalten ve Green'in (1999) sunduğu yöntemle belirlenmiştir [14]. Doğruluk analizi için, Şekil 2(f)'de gösterilen yer gerçeği kullanılarak hata matrisi oluşturulmuştur. Doğruluk analizi için kullanılan IoU, genel doğruluk, kullanıcı doğruluğu ve üretici doğruluğu aşağıda belirtildiği gibi hesaplanır.

Genel doğruluk test verisi içinde doğru olarak tahmin edilen tüm piksellerin, toplam piksel sayısına oranlamasıyla bulunur.

$$\text{Genel Doğruluk} = \frac{DP + DN}{(DP + YP + YN + DN)} \quad (11)$$

Kullanıcı doğruluğu, modelin yanlış negatiflerden ne kadar iyi kaçındığını belirler. Doğru gerçek değerlerin tüm gerçek değerlere olan oranıdır. Kullanıcı doğruluğu sınıflandırma sonucu oluşan çıktı görüntüsünün güvenilirliğini ölçer. Kullanıcı doğruluğu tahmin edilen değer gerçekte ne kadarının yeryüzünde kendi sınıfına ait olup olmadığını ölçtüdür.

$$\text{Kullanıcı Doğruluğu} = \frac{DP}{(DP + YN)} \quad (12)$$

Üretici doğruluğu eğitim ve test verilerinin kaç tanesinin doğru bir şekilde sınıflandırıldığının ölçütüdür. Diğer bir deyişle üretici doğruluğu tahmin edilen değerlerin gerçekte kaç tanesinin doğru tahmin edildiğini gösterir.

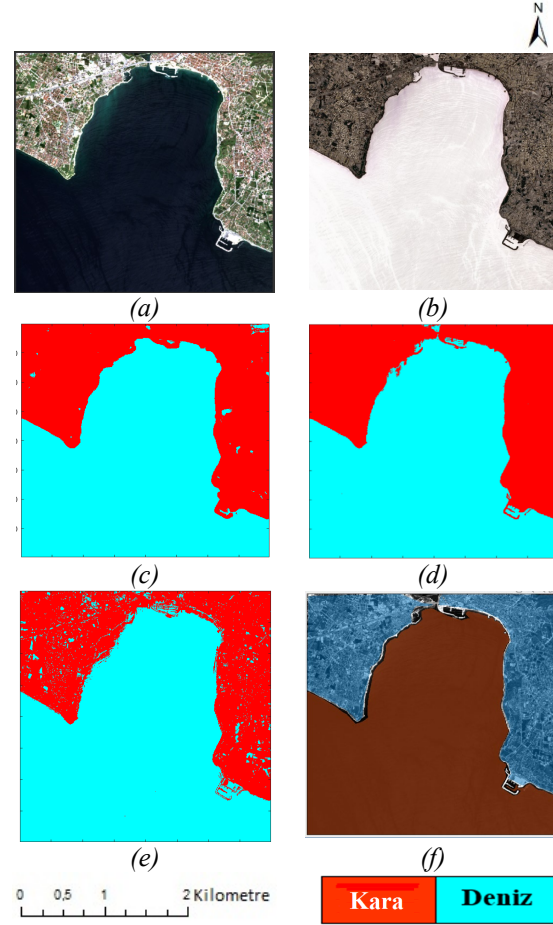
$$\text{Üretici Doğruluğu} = \frac{DP}{(DP + YP)} \quad (13)$$

IoU, bilgisayarla görü alanındaki gelişmelerle birlikte bölütleme sonuçlarını kullanan bir metrik olup, yersel doğrulama görüntüsü ile sınıflandırma sonrası çıktı görüntüsü arasındaki kesişen alanların, toplam alana olan oranıdır [15].

$$\text{IoU} = \frac{TP}{TP + FP + FN} \quad (14)$$

## 5. BULGULAR VE TARTIŞMA

Bölütleme sonrası RO, DVM ve Mean-Shift yöntemlerine ait sonuç görüntüleri Şekil 2’de verilmiştir. Sonuçlar görsel olarak incelendiğinde RO, kara alanlarındaki yoğun orman alanlarını yer yer deniz sınıfı olarak bulmuştur (Şekil 2c). Kıyı boyunca girintili ve çıkıntılı alanları detaylı bir şekilde belirleyememiştir. DVM, kıyı sınırı boyunca var olan nesnelere detaylarını belirlemede RO’ya göre daha iyidir (Şekil 2.d). Mean-Shift yöntemi, RO gibi kara alanlarını deniz olarak belirlemiş ve kıyı üzerinde olan iskele gibi yapıları tam olarak çıkarmakta yetersiz kalmıştır (Şekil 2.e)



Şekil 2. RGB (a), 4 BANT (Kırmızı, Yeşil, Mavi, Yakın kızılötesi bant kombinasyonu)(b), RO (c), DVM (d), Mean- Shift (e), Yer Gerçeği (f)

RO	Kara	Deniz
Kara	229033	4356
Deniz	1070	402345

DVM	Kara	Deniz
Kara	225661	7728
Deniz	871	402544

Mean-Shift	Kara	Deniz
Kara	221229	12160
Deniz	5464	397951

Şekil 3. RO, DVM ve Mean-Shift yöntemlerine ait hata matrisleri

**Çizelge 2.** Doğruluk analizi sonucu elde edilen IoU, üretici doğruluğu, kullanıcı doğruluğu ve genel doğruluk değerleri

Yöntem	Etiket sınıfları	IoU	ÜD	KD	GD
RO	Kara	97.69	99.53	98.13	99.15
	Deniz	98.67	98.93	99.73	
DVM	Kara	96.33	99.62	96.69	98.65
	Deniz	99.78	98.12	99.78	
Mean-shift	Kara	92.62	97.58	94.79	97.23
	Deniz	95.76	97.03	98.65	

Kara sınıfı en yüksek IoU değeri RO, deniz sınıfı içinse DVM'den elde edilmiştir. Genel doğruluklar RO, DVM ve Mean-Shift için sırasıyla %99.15, %98.65 ve %97.23'tür. Üretici doğrulukları kara ve deniz sınıfları için RO ve DVM yöntemleri birbirine yakın olup sırasıyla %98 ve %99 civarındadır. Mean-Shift yöntemi için etiket sınıflarının üretici doğrulukları %97'de kalmıştır. Kullanıcı doğrulukları kara etiket sınıfı için RO, DVM ve Mean-Shift için sırasıyla %98.13, %96.69 ve %94.79'dur. Deniz etiket sınıfı içinse %99.73, %99.78 ve %98.65'dir. Mean-Shift yöntemi detayları çıkarmada iyi olmayıp, RO gibi kara alanlarındaki yerleri deniz olarak bölütlemiştir. Bunun sebebi Mean-Shift yönteminin spektral yansıma değerlerine yani renk bilgisine oldukça duyarlı olmasıdır. DVM, yakın ve benzer yansıma değerlerinin üstesinden gelmiş ve görsel olarak incelediğinde daha iyi bir sonuç vermiştir. RO yöntemi ise farklı yansımardan etkilenmiş olup DVM kadar başarılı olamamıştır.

Makale kapsamında kıyı çizgisinin çıkarımı, yapılan çalışmalar ile karşılaştırıldığında Kumar vd., (2020), Hindistan Odissa kıyısı için K-En yakın komşu (KNN), DVM, yapay sinir ağları yöntemleri kullanarak yaptıkları çalışmada %80-%84 arasında bir doğruluk elde etmişlerdir [22]. Makale kapsamında kıyı çizgisinin belirlenmesi için üretilen doğruluk %14-%18 arasında bir artış sağlamıştır. Erdem vd., (2021), derin öğrenme yöntemleri (WaterNet) ile kıyı çizgisini %99 doğrulukla belirlemişlerdir [23]. Makale kapsamında sadece RO yöntemi ile aynı sonuç elde edilmiştir. Dang vd., (2022), derin öğrenme mimarileri olan U-NET mimarileri ile yaptıkları çalışmada %97 ve %98 olan genel doğruluklar

elde etmişlerdir. Bu sonuç makale sonuçları ile aynı olup, RO yöntemi %1 artış göstermiştir. Son dönemde derin öğrenme yöntemleri ile yapılan çalışmalar ile doğruluk artsa da, derin öğrenme mimarileri yüksek performanslı bir donanıma ve büyük verilere ihtiyaç duymaktadır. Bu noktada makine öğrenmesi yöntemleri, derin öğrenme yöntemlerinden çok az bir farkla doğruluk üreterek, daha düşük donanım ve veri ile kıyı sınırlarının ayrılmasına olanak sağlamaktadır.

## 6. SONUÇLAR

Bu çalışma kapsamında ilgili çalışma bölgesi üzerinde Sentinel-2A uydu görüntüsü kullanılarak RO, DVM ve Mean-Shift makine öğrenmesi yöntemleriyle kıyı çizgisi belirlenmiştir. Elde edilen genel doğruluklar RO, DVM ve Mean-Shift için sırasıyla %99.15, %98.65 ve %97.23'tür. RO ile en yüksek genel doğruluk elde edilse de sonuçlar görsel olarak incelediğinde kara sınıfını yer yer deniz olarak bölütlediği görülmüştür. DVM, kıyı çizgisi üzerindeki obje detaylarının çıkarılmasında RO ve Mean-Shift'e nazaran daha iyidir. Sonuç olarak, RO, DVM ve Mean-Shift makine öğrenmesi yöntemleri %95'in üzerinde bir genel doğruluk ürettikleri için kıyı çizgisinin belirlenmesinde başarılı oldukları tespit edilmiştir.

## 7. KAYNAKLAR

- Doğan, E., Burak, S., Akkaya, M.A., 2005. Türkiye Kıyıları; Kavramsal Tanımlama, Planlama, Kullanım. Beta Basım Dağ. Şti., İstanbul. 238. ISBN 978-975-295-495-3.
- Akengin, H., Dölek, İ., Özdemir, Y., 2016. Türkiye'nin Denizleri ve Kıyıları. 345. ISBN: 975-295-495-2.
- Şatıroğlu, E., Yıldızcı, A.C., 2015. İstanbul'un Doğu Karadeniz Kıyı Alanları Kullanımlarındaki Değişimin Saptanması. Akademik Ziraat Dergisi, 3(1), 33-40.
- Ünel, B.F., Kuşak, L., Çelik, M., Alptekin, A., Yakar, M., 2020. Kıyı Çizgisinin Belirlenerek Mülkiyet Durumunun İncelenmesi. Türkiye Arazi Yönetimi Dergisi, 2(1), 33-40.
- Erdem, F., Derinpınar, M. A., Nasırzadehdıza, R., Oy, S., Şeker, D.Z.,

- Bayram, B., 2018. Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği. *Geomatik*, 3(2), 100-107. DOI: 10.29128/geomatik.362179.
6. Çoban, H., Koç, Ş., Kale, M.M., 2020. Çoruh Deltası (Gürcistan/Batum) Kıyı Çizgisi Değişimi (1984-2019). *International Journal of Geography and Geography Education*, (42), 589-601. DOI: 10.32003/igge.741573.
7. Aykut, N.O., 2019. İnsansız Hava Araçlarının Kıyı Çizgisinin Belirlenmesinde Kullanılabilirliğinin Araştırılması. *Geomatik*, 4(2), 141-146. DOI: 10.29128/geomatik.503055.
8. Kılar, H. Çiçek, İ., 2019. Kıyı Çizgisinin Gelecekteki Konumunun Belirlenmesinin Önemi: Göksu Deltası Örneği, Mersin (Türkiye). *Coğrafi Bilimler Dergisi*, 17(1), 193-216. DOI: 10.33688/aucbd.559328.
9. Kaplan, G., Avdan, U., 2017. Object-based Water Body Extraction Using Sentinel-2 Satellite Imagery, *European Journal of Remote Sensing*, 50(1), 137-143. DOI:10.1080/22797254.2017.1297540.
10. Comaniciu D., Meer, P., Mean Shift: A Robust Approach Toward Feature Space Analysis, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5), 603-619, May 2002. DOI: 10.1109/34.1000236.
11. Breiman, L., 2001. Random Forests. *Machine Learning*, 45, 5-32.
12. Cortes, C., Vapnik, V., 1995. Support-vector Networks. *Machine Learning*, 20(3), 273-297.
13. Demirci M., 2019. Destek Vektör Makineleri ve M5 Karar Ağacı Yöntemleri Kullanılarak Yağış Akış İlişkisinin Tahmini, *Dicle Üniversitesi, Mühendislik Fakültesi Dergisi*, 10(3), 1113-1124.
14. Uslu E., Bilgin, G., 2008. Classification of Heart Arrhythmias by Using Wavelet and Merged Wavelet Packet Transforms, 2008 IEEE 16<sup>th</sup> Signal Processing, Communication and Applications Conference, 2008, 1-4. DOI: 10.1109/SIU.2008.4632600.
15. Congalton, R.G., Green, K., 1999. Assessing the Accuracy of Remotely Sensed Data Principles and Practices. Lewis Publishers, Boca Raton, 348.
16. Van Beers, F., Lindström, A., Okafor, E., Wiering, M.A., 2019. February. Deep Neural Networks with Intersection over Union Loss for Binary Image Segmentation. In *ICPRAM* (438-445).
17. Di, K., Wang, J., Ma, R., Li, R. 2003. May. Automatic Shoreline Extraction From High-Resolution IKONOS Satellite Imagery. In *Proceeding of ASPRS 2003 Annual Conference*, 3.
18. Bamdadinejad, M., Ketabdari, M.J., Chavooshi, S.M.H., 2021. Shoreline Extraction Using Image Processing of Satellite Imageries. *Journal of the Indian Society of Remote Sensing*, 49(10), 2365-2375.
19. Billa, L., Pradhan, B., 2011. Semi-automated Procedures for Shoreline Extraction Using Single RADARSAT-1 SAR Image. *Estuarine, Coastal and Shelf Science*, 95(4), 395-400.
20. Rishikeshan, C.A., Ramesh, H., 2017. A Novel Mathematical Morphology Based Algorithm for Shoreline Extraction from Satellite Images. *Geo-spatial Information Science*, 20(4), 345-352.
21. El Kafrawy, S.B., Basiouny, M.E., Ghanem, E.A., Taha, A.S., 2017. Performance Evaluation of Shoreline Extraction Methods Based on Remote Sensing Data. *Journal of Geography, Environment and Earth Science International*, 11(4), 1-18.
22. Kumar, L., Afzal, M.S., Afzal, M.M., 2020. Mapping Shoreline Change Using Machine Learning: A Case Study from the Eastern Indian Coast. *Acta Geophysica*, 68(4), 1127-1143.
23. Erdem, F., Bayram, B., Bakirman, T., Bayrak, O.C., Akpınar, B., 2021. An Ensemble Deep Learning Based Shoreline Segmentation Approach (WaterNet) from Landsat 8 OLI Images. *Advances in Space Research*, 67(3), 964-974.
24. Dang, K.B., Vu, K.C., Nguyen, H., Nguyen, D.A., Nguyen, T.D.L., Pham, T.P.N., Do, T.H., 2022. Application of Deep Learning Models to Detect Coastlines and Shorelines. *Journal of Environmental Management*, 320, 115732.