

T.C.  
YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

AKTARIMLI ÖĞRENME İLE SENTINEL-2 UYDU  
GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ ÇIKARIMI

**Selennur Karagöl**

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Uzaktan Algılama ve CBS Programı

Danışman

Prof. Dr. Bülent Bayram

Şubat, 2021

**T.C.**  
**YILDIZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**AKTARIMLI ÖĞRENME İLE SENTİNEL-2 UYDU GÖRÜNTÜLERİNDEN**  
**KIYI ÇİZGİSİ ÇIKARIMI**

Selennur KARAGÖL tarafından hazırlanan tez çalışması 09/02/2021 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Uzaktan Algılama ve CBS Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Bülent BAYRAM  
Yıldız Teknik Üniversitesi  
Danışman

**Jüri Üyeleri**

Prof. Dr. Bülent BAYRAM, Danışman

Yıldız Teknik Üniversitesi

Prof. Dr. Füsun BALIK ŞANLI, Üye

Yıldız Teknik Üniversitesi

Prof. Dr. Cem GAZİOĞLU, Üye

İstanbul Üniversitesi

---

---

---

Danışmanım Prof. Dr. Bülent BAYRAM sorumluluğunda tarafımca hazırlanan Aktarımlı Öğrenme İle SENTINEL-2 Uydu Görüntülerinden Kıyı Çizgisi Çıkarımı başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Selennur KARAGÖL

İmza

## TEŞEKKÜR

---

Değerli görüş ve tavsiyeleri ile tez çalışması boyunca katkıda bulunan sevgili danışmanım Prof. Dr. Bülent BAYRAM'a,

Çalışmalarım boyunca zaman zaman fikirlerine ve tavsiyelerine başvurduğum çalışma arkadaşlarım Harita Mühendisi Gizem KAYA, Harita Yüksek Mühendisi Onur Can Bayrak ve Harita Yüksek Mühendisi Fırat ERDEM'e

Tez çalışmam boyunca her zaman bana destek ve yardımcı olan Harita Mühendisi İrem İSMAİLOĞLU, Harita Mühendisi Balahun KALKAN ve Harita Mühendisi Gamze DOYMAZ'a

Maddi ve manevi destekleri ile hayatımın her anında yanımda sevgili ailem; Sebahattin KARAGÖL, Asiye KARAGÖL, Sedef KARAGÖL ve Eslem KARAGÖL'e

Eğitim hayatım boyunca koşulsuz yanımda olan, her zaman destekleyen ve fikirlerini sunan, hedeflerimi gerçekleştirmemde büyük bir rolü bulunan Doktor Arda KARAKAYA'ya sonsuz teşekkürlerimi sunarım.

Selennur KARAGÖL

# İÇİNDEKİLER

<b>SİMGE LİSTESİ</b>	vi
<b>KISALTMA LİSTESİ</b>	vii
<b>ŞEKİL LİSTESİ</b>	viii
<b>TABLO LİSTESİ</b>	x
<b>ÖZET</b>	xi
<b>ABSTRACT</b>	xiii
<b>1 GİRİŞ</b>	1
1.1 Literatür Özeti .....	1
1.2 Tezin Amacı .....	6
1.3 Hipotez.....	6
<b>2 GENEL BİLGİLER</b>	7
2.1 Kıyı Çizgisine Ait Tanımlar .....	7
2.2 Kıyı Çizgisinin İzlenmesinin Önemi.....	8
2.3 Kıyı Çizgisi Çıkarımında Uzaktan Algılama .....	10
<b>3 YÖNTEM</b>	11
3.1 Derin Öğrenme .....	11
3.2 Konvolüsyonel Sinir Ağları .....	12
3.2.1 Girdi Katmanı.....	13
3.2.2 Konvolüsyon Katmanı.....	13
3.2.3 Aktivasyon Fonksiyonları .....	14
3.2.4 Havuzlama Katmanları.....	15
3.2.5 Tam Bağlı Katman ve Softmax Katmanı.....	16
3.2.6 Konvolüsyonel Sinir Ağlarında Eğitim Parametreleri .....	17
3.3 Konvolüsyonel Sinir Ağlarında Sematik Bölütleme .....	19
3.3.1 U-Net Mimarisi.....	20
3.4 Aktarımlı Öğrenme .....	21

3.5 Doğruluk Analizi .....	22
3.5.1 Karşılaştırma Matrisi.....	23
3.5.2 Sayısal Kıyı Çizgisi Analiz Sistemi .....	24
<b>4 UYGULAMA</b> .....	<b>26</b>
4.1 Kullanılan Yazılım ve Donanım .....	26
4.2 Materyal .....	26
4.2.1 Veri Seti .....	27
4.3 Eğitim Veri Setinin Oluşturulması .....	29
4.4 Aktarımlı Öğrenme ve U-Net.....	33
4.5 Kıyı Çizgilerinin Elde Edilmesi .....	35
4.6 Doğruluk Analizi .....	39
4.6.1 Karşılaştırma Matrisi.....	39
4.6.2 Sayısal Kıyı Çizgisi Analiz Sistemi .....	40
<b>5 SONUÇ VE ÖNERİLER</b> .....	<b>43</b>
<b>KAYNAKÇA</b> .....	<b>45</b>
<b>TEZDEN ÜRETİLMİŞ YAYINLAR</b> .....	<b>49</b>

## SİMGE LİSTESİ

---

$X_i$  Kıyı çizgileri arasında kalan dik mesafe



## KISALTMA LİSTESİ

---

AWEI	Otomatik Su Çıkarma İndeksi
CNN	Convolution Neural Networks
DN	Doğru Negatif
DP	Doğru Pozitif
DSAS	Digital Shoreline Analysis System
ISODATA	Iterative Self-Organizing Data Analysis Technique
KOH	Karesel Ortalama Hata
KSA	Konvolüsyonel Sinir Ağları
NDBI	Normalized Difference Built Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
OH	Ortalama Hata
OSM	OpenStreetMap
ReLU	Rectified Linear Unit
RGB	Kırmızı-Yeşil-Mavi bant
SSAE	Stacked Sparse Autoencoder
SWIR	Kısa Dalga Kızılötesi
YN	Yanlış Negatif
YP	Yanlış Pozitif

## ŞEKİL LİSTESİ

---

<b>Şekil 2.1</b> Kıyı Kanunu'na göre kıyı ile ilgili tanımları gösteren kroki .....	8
<b>Şekil 2.2</b> Kıyı çizgisinin yıllar içinde değişimi .....	9
<b>Şekil 3.1</b> Derin öğrenme ve klasik makine öğrenmesi .....	11
<b>Şekil 3.2</b> Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi ve kronolojisi	12
<b>Şekil 3.3</b> Düşük, orta ve yüksek seviyeli özellikler .....	12
<b>Şekil 3.4</b> Konvolüsyonel Sinir Ağı yapısı .....	13
<b>Şekil 3.5</b> Konvolüsyon işlemi .....	14
<b>Şekil 3.6</b> Aktivasyon fonksiyonları .....	15
<b>Şekil 3.7</b> Aktivasyon fonksiyonlarının özellik haritasına etkisi .....	15
<b>Şekil 3.8</b> Maksimum havuzlama işlemi .....	16
<b>Şekil 3.9</b> Tam Bağlı Katman .....	17
<b>Şekil 3.10</b> Dropout kullanımı .....	19
<b>Şekil 3.11</b> Derin öğrenme yönteminin görüntü analizinde kullanımı .....	20
<b>Şekil 3.12</b> U-Net mimarisi .....	21
<b>Şekil 3.13</b> Derin öğrenme ve aktarımlı öğrenme arasındaki eğitim süreçleri .....	22
<b>Şekil 3.14</b> DSAS yapısı .....	24
<b>Şekil 4.1</b> İş akışı .....	27
<b>Şekil 4.2</b> Eğitim ve test için kullanılan SENTINEL-2 görüntülerinin konumları .....	29
<b>Şekil 4.3</b> Eğitim verisinde kullanılan 10980x10980 boyutlarındaki görüntü .....	30
<b>Şekil 4.4</b> Kara ve su sınıflarını gösteren ikili görüntü örneği .....	31
<b>Şekil 4.5</b> Eğitim veri setinden örnekler .....	32
<b>Şekil 4.6</b> Aktarımlı öğrenme eğitimi boyunca elde edilen doğruluklar .....	35
<b>Şekil 4.7</b> Portekiz test görüntüsü için ikili görüntü .....	35

<b>Şekil 4.8</b> İtalya test görüntüsü için ikili görüntü .....	36
<b>Şekil 4.9</b> Mısır test görüntüsü için ikili görüntü .....	36
<b>Şekil 4.10</b> Finlandiya test görüntüsü için ikili görüntü .....	36
<b>Şekil 4.11</b> Kırım test görüntüsü için ikili görüntü .....	36
<b>Şekil 4.12</b> Amerika test görüntüsü için ikili görüntü .....	37
<b>Şekil 4.13</b> Riga test görüntüsü için ikili görüntü .....	37
<b>Şekil 4.14</b> Portekiz ve İtalya test görüntüleri için çıkartılan kıyı çizgileri .....	37
<b>Şekil 4.15</b> Mısır ve Finlandiya test görüntüleri için çıkartılan kıyı çizgileri .....	38
<b>Şekil 4.16</b> Kırım ve ABD test görüntüleri için çıkartılan kıyı çizgileri.....	38
<b>Şekil 4.17</b> Riga test görüntüsü için çıkartılan kıyı çizgileri .....	38
<b>Şekil 4.18</b> DSAS elemanları .....	41

## TABLO LİSTESİ

---

<b>Tablo 3.1</b> Karşılaştırma Matrisi .....	23
<b>Tablo 4.1</b> SENTINEL- 2 uydu görüntülerine ilişkin teknik bilgiler [51].....	27
<b>Tablo 4.2</b> Kullanılan eğitim parametreleri .....	34
<b>Tablo 4.3</b> Test görüntüleri için karşılaştırma matrisi doğrulukları.....	39
<b>Tablo 4.4</b> U-Net ağı için ortalama hata değerleri .....	41



## Aktarımlı Öğrenme ile SENTINEL-2 Uydu Görüntülerinden Kıyı Çizgisi Çıkarımı

Selennur KARAGÖL

Harita Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Bülent Bayram

Kıyı alanları, insan etkileri ve doğal sebeplerden kaynaklanan dinamik değişimlerin olduğu, ekonomik ve sosyal açıdan nitelikli bölgelerdir. Kıyı çizgileri küresel ısınma, nüfus artışı, çevre kirliliği, kentleşme etkileriyle sürekli bir değişim içindedir. Doğal ve antropojenik etkilerle meydana gelen değişimlerin izlenmesi; kıyı kaynak yönetimi, çevresel koruma, erozyon yönleri, kıyı çizgisinin gelecekteki konumlarının belirlenmesi, güvenli navigasyon ve kıyı planlaması için önemlidir. Uydu görüntüleri kıyı çizgilerinin izlenmesi için anlık, doğru, güvenilir ve güncel sonuçlar sağlamaktadır. Son teknoloji derin öğrenme ve aktarımlı öğrenme yaklaşımları kıyı çizgisinin çıkarılması için yeni olanaklar sağlar. Sunulan tezde, aktarımlı öğrenmeye dayalı kıyı çizgisi çıkarımı için SENTINEL-2 uydu görüntüleri ve U-Net derin öğrenme mimarisi kullanılmıştır. U-Net mimarisi; kodlayıcı ve kod çözücü olmak üzere iki aşamadan oluşmaktadır. Bu mimaride kodlayıcı katmanlarında üretilen özellik haritaları veri kaybını aza indirmek için özellik aktarımı ile kod çözücü katmanlarına aktarmaktadır. Çalışmada, tam çerçeve 15 adet SENTINEL-2 uydu görüntülerinin mavi, kırmızı ve yakın kızılötesi bantları kullanılmıştır. Kullanılan 15 SENTINEL-2 uydu görüntülerinden 8 tanesi U-Net derin öğrenme ağının eğitim aşaması için ve 7 tanesi eğitilen ağın test aşaması için kullanılmıştır. Eğitim görüntülerinin etiketli verilerini üretmek amacıyla ilk olarak OpenStreetMap (OSM) kullanılarak su sınıflarının vektör verileri oluşturulmuştur.

Oluşturulan vektör veriler üzerinde elle düzeltme yapılarak su (siyah) ve kara (beyaz) sınıflarını belirten ikili görüntüler hazırlanmıştır. Tam çerçeve uydu görüntüleri ve etiketli görüntüler 512x512 piksel boyutlarında kırılmıştır ve 115 adet görüntü parçası içeren eğitim veri seti hazırlanmıştır. Önceden eğitilmiş modele ait özellikler ve ağırlıklar için LANDSAT-8 uydu görüntüleri ile gerçekleştirilen derin öğrenme çalışmasından yararlanılmıştır. Python platformunda hazırlanmış eğitim veri seti ve önceden eğitilmiş modelin ağırlıkları kullanılarak eğitim işlemi gerçekleştirilmiştir. U-Net derin öğrenme ağı kullanılarak, 7 adet test görüntüsünden su ve kara sınıflarını içeren ikili görüntüler elde edilmiştir. Elde edilen ikili görüntülerin vektör formatı oluşturularak kıyı çizgileri elde edilmiştir. Kıyı çizgilerinin doğruluğunu analiz etmek için elle sayısallaştırılan kıyı çizgileri ve bölütleme doğruluğunu analiz etmek için sayısallaştırılan kıyı çizgilerinden oluşturulan ikili görüntüler kullanılmıştır. Sayısallaştırılan kıyı çizgileri ve ikili görüntüler doğruluk analizi için referans veriler olarak kullanılmıştır. Çalışma sonucunda; bölütleme doğruluk analizi için ortalama doğruluk, duyarlılık, hassasiyet, özgünlük ve F-Skor değerleri sırasıyla 0.9917, 0.9927, 0.9908, 0.9907 ve 0.9917 olarak hesaplanmıştır. Kıyı çizgileri için ortalama hata sırasıyla 7 Portekiz için 7.09 m, İtalya için 5.42 m, Mısır için 7.65 m, Finlandiya için 8.02 m, Kırım için 5.7 m, ABD için 3.40 m ve Riga için 3.65 m olarak hesaplanmıştır. Tez çalışma sonuçları, U-Net mimarisi ve aktarımlı öğrenme kullanılarak az sayıda görüntü ile kıyı çizgisi çıkarımının mümkün olduğunu göstermektedir.

**Anahtar Kelimeler:** Aktarımlı öğrenme, U-Net, bölütleme, kıyı çizgisi çıkarımı, SENTINEL-2

## **Shoreline Extraction from SENTINEL-2 Imagery by Transfer Learning**

Selennur KARAGÖL

Department of Photogrammetry of Geomatics Engineering

MSc. Thesis

Advisor: Prof. Dr. Bülent Bayram

Global warming, increasing population, environmental pollution and urbanization can constantly affect shorelines. Sustainable monitoring of coastal zones is vital to detect changes which can occur due to natural and anthropogenic effects. Thus, sustainable shoreline monitoring is essential for coastal resource management, environmental protection and planning, navigation, directions of erosion and estimating future positions of the shorelines. Satellite images provide accurate, reliable, temporal and up-to-date information for shoreline monitoring. State-of-the-art deep learning (DL) and transfer learning approaches brought opportunities for shoreline extraction. In this thesis, SENTINEL-2 satellite images and U-Net deep learning architecture were used for shoreline extraction based on transfer learning. U-Net architecture consists of two stages: encoder layers and decoder layers. In this architecture, feature maps in the encoder layers were transferred to decoder layers by feature transfer in order to minimize data loss. In this study, 15 full frame SENTINEL-2 satellite images which has blue, red and near infrared bands have been used. 8 of SENTINEL-2 images have been used for training phase of the U-Net network and 7 of them for testing phase of the trained network. In order to generate labels of training data, vector data of water body were created by OpenStreetMap(OSM). Binary images have been prepared by manually editing on

vector data. Full frame satellite images and labels have been cropped as 512x512 pixels. 115 and 235 patches have been created for the training and testing dataset, respectively. The pre-trained weights have been obtained from another study which is a network trained with LANDSAT-8 imageries. The training process was carried out using pre-trained weights and prepared training set in Python. By U-Net architecture, land-water bodies have been obtained as binary images from 7 test images. All binary images were converted to vector form and shorelines were obtained. Confusion matrix and DSAS have been used for accuracy assessment. According to result of study; average accuracy, recall, precision, specificity and F-score of the model values has been calculated as 0.9917, 0.9927, 0.9908, 0.9907 and 0.9917, respectively. The average errors have been calculated as 7.09 m (Portugal), 5.42 m (Italy), 7.65 m (Egypt), 8.02 m (Finland), 5.7 m (Crimea), 3.40 m (USA) and 3.65 m (Riga). The results show that it is possible to obtain high accurate shoreline with limited data using transfer learning.

**Keywords:** Transfer learning, U-Net, segmentation, shoreline extraction, SENTINEL-2

### 1.1 Literatür Özeti

Kıyı çizgisini çıkartmak için fotogrametrik yöntemler, GPS teknolojisi ve yersel ölçüler, uzaktan algılama gibi yöntemler kullanılmaktadır [1]. LANDSAT uydusunun 1972'de kullanılmaya başlanılmasından şimdiye dek optik uzaktan algılama verileri diğer yöntemlerden elde edilen verilere bir alternatif haline gelmiştir [2]. Uydu görüntüleri kıyı çizgileri elde etmek için doğru, güvenilir, zamansal ve güncel bilgiler sağlamaktadır. Son yıllarda uzaktan algılama alanının araştırma konularından biri haline gelen kara-su bölütlemesi kıyı kaynak yönetimi, kıyı planlama ve çevresel koruma açısından önemli bir role sahiptir.

Kontrolsüz ve kontrollü sınıflandırma yöntemleri kıyı çıkartılmasında sıklıkla kullanılmıştır. İşıaçık Çolak vd., LANDSAT-8 OLI Bodrum Yarımadası görüntülerine üç farklı kıyı çizgisi çıkarma yöntemi uygulamışlardır. Otomatik Su Çıkarma İndeksi (AWEI), kontrolsüz sınıflandırma tekniği olan Iterative Self-Organizing Data Analysis Technique (ISODATA) ve elle sayısallaştırma yöntemlerini kullanmışlardır. ISODATA kontrolsüz sınıflandırma tekniğini, kara ve su alanlarını iki ayrı sınıfa ayırmak için tercih etmişlerdir. Sınıflandırmadan elde edilen su-kara sınıflarını içeren görüntü vektör verilerine dönüştürülerek kıyı çizgisi elde etmişlerdir. Üç ayrı yöntemle kıyı çizgisi elde edildikten sonra elle sayısallaştırılan kıyı çizgisi referans çizgisi alınarak sonuçları birbirleriyle karşılaştırmışlardır. Çalışma sonuçları incelendiğinde AWEI yönteminin ISODATA sınıflandırmasına göre daha doğru kıyı çizgisi çıkardığı görülmektedir [3].

Kıyı çizgisini elde etmek için kullanılabilecek birçok otomatik ve yarı otomatik uzaktan algılama tekniği mevcuttur. Salleh vd., bu tekniklerden hangisinin daha iyi doğruluk sunduğunu belirlemek için bir çalışma yapmışlardır. Bu çalışmanın amacı kıyı çizgisinin çıkarılması için en uygun yöntemi belirlemektir. Bu amaçla, LANDSAT-8 OLI görüntülerinden kıyı çizgisi çıkarmak için Band Ratio, Tasselled

Cap Transformation, ISODATA ve NDWI (Normalleştirilmiş Fark Su İndeksi - Normalized Difference Water Index) olmak üzere dört farklı yöntem kullanmışlardır. Sunulan çalışmanın sonuçları incelendiğinde kıyı çizgisi çıkarımı için Bant Oranı yönteminin test edilen diğer tekniklerle karşılaştırıldığında en yüksek doğruluğu sunduğunu görülmektedir [4].

Bir başka çalışmada Pham ve Prakash, Hindistan'ın Diu Adası kıyı çizgisini otomatik olarak çıkarmak amacıyla uydu görüntülerinden kara-su sınıflandırması için NDVI (Normalleştirilmiş Fark Bitki İndeksi - Normalized Difference Vegetation Index) ve NDWI (Normalleştirilmiş Fark Su İndeksi - Normalized Difference Water Index) uzaktan algılama teknikleri kullanmışlardır. Oluşturulan NDVI ve NDWI görüntüleri, kıyı çizgisini çıkarmak için ikili görüntü biçimine dönüştürülmüştür. NDWI ve NDVI tekniklerini doğruluğunu değerlendirmek için Google Earth Görüntülerinin kıyı çizgisi sınırlarını kullanmışlardır. Çalışma sonuçları, her iki yöntemin de su sınıflarının belirlenmesinde ve kıyı çizgisinin çıkarılmasında yararlı olduğunu göstermiştir. Bununla birlikte, NDWI görüntüleri su sınıflarının belirlenmesinde NDVI görüntülerine göre daha yüksek doğruluk verdiği görülmektedir [5].

Uydu görüntülerinden kıyı çizgisi çıkarımında piksel ve nesne tabanlı teknikler de yapılan çalışmalar içinde yer almıştır. Hafizi ve Kalkan, su sınıfının bölütlenmesi için nesne tabanlı, piksel tabanlı ve su indekslerinin etkinliğini değerlendirmişlerdir. LANDSAT-8 uydusuna ait 30m çözünürlüğe sahip kırmızı-mavi-yeşil, yakın kızılötesi, SWIR (Kısa Dalga Kızılötesi) ve 15m çözünürlükteki pankromatik bantları kullanılmıştır. Nesne tabanlı yaklaşım için Kenar Tabanlı Bölütleme (Edge Based Segmentation) algoritması ve Destek Vektör Makineleri (Support Vector Machines), piksel bazlı sınıflandırma için ise Maximum Likelihood ve K-ortalama sınıflandırma yöntemi seçilmiştir. Su indeksi olarak su sınıflarını uydu görüntülerinden çıkarmak için Normalleştirilmiş Fark Su İndeksi (NDWI) seçilmiştir. Çalışma alanı Türkiye'de bulunan farklı özelliklere sahip şehir içi ve dağlık bölgelerdir. Sonuçlar, su bölütlemesi için nesne tabanlı yöntemlerin piksel tabanlı ve NDWI yöntemlerine kıyasla daha doğru olduğunu göstermiştir. Sunulan çalışma sonucunda, nesne tabanlı yöntemin avantajının sadece yüksek

çözünürlükte değil aynı zamanda orta çözünürlükteki uydu görüntülerinde de kullanılabilmesi iken dezavantajı su alanlarının bazı küçük parçaları yanlış bölütlemesi olduğu gözlemlenmiştir [6].

Son yıllarda uzaktan algılama problemlerinde makine öğrenmesi yöntemleri yaygın olarak kullanılmaktadır [7]. Makine öğrenimi yöntemleri kıyı çizgisi bölütleme için de tercih edilmektedir.

Kıyı bölgeleri hem doğal hem de antropojenik etkiler sebebiyle değişim içinde olduğundan kıyı çizgisinde meydana gelen değişimlerin belirlenmesi kıyıda oluşabilecek olumsuz durumların değerlendirilmesi açısından önemlidir. Bu amaçla Kumar vd., Doğu Hindistan kıyılarında sel nedeniyle oluşan kıyı erozyonunu, bunun sebep olduğu kıyı çizgisi değişikliğini belirlemek için makine öğrenme algoritmalarını kullanmışlardır. K- En Yakın Komşu (K- Nearest Neighbours), Yapay Sinir Ağları ve Destek Vektör Makineleri (Support Vector Machines) LANDSAT uydu görüntülerinden kıyı çizgisi çıkartmak için kullanılmıştır. Çalışma sonuçlarından Yapay Sinir Ağları, kıyı çizgisi belirlemede % 86,2'lik bir doğrulukla K- En Yakın Komşu ve Destek Vektör Makineleri algoritmasından daha iyi performans gösterdiği anlaşılmaktadır. 2018'deki kıyı çizgisi referans olarak alınmıştır ve 1985'ten 2015'e kadar kıyı çizgisinde 2.6 m/yıl oranında bir azalma olduğu görülmektedir [8].

Bir diğer çalışmada Bayram vd., makine öğrenmesi tekniklerinden biri olan Rastgele Orman algoritmasını Karadeniz'in Terkos Gölü'ne yakın kıyı çizgisini çıkartmak için kullanmışlardır. Kara ve su sınıflarını bölütlemek için LANDSAT-8 (5. bant) ve GÖKTÜRK-2 (4. bant) görüntülerinin yakın kızılötesi bantlarına Rastgele Orman yöntemi uygulanmıştır. Doğruluk analizi için her görüntü manuel olarak sayısallaştırılmıştır. Doğruluk analizi sonuçlarına bakıldığında Rastgele Orman yöntemi, kıyı çizgisi çıkartma çalışmaları için hem orta hem de yüksek çözünürlüklü görüntüler için etkili olduğu anlaşılmaktadır [9].

Klasik makine öğrenmesinde kullanıcı tarafından yapılan özellik çıkartma işleminde kullanılması gereken özelliklere karar verilebilmesi için kullanıcının veri setini anlaması ve uzun süre boyunca analiz etmesi gerekmektedir. Ancak derin öğrenmede özellik çıkartma işleminde aksi bir durum söz konusudur. Başka bir

deyişle, derin öğrenme algoritmaları özellik çıkartma işlemini kendi kendine otomatik olarak gerçekleştirir [10]. Son yıllarda kıyı alanları ile ilgili çalışmalarda derin öğrenme yöntemleri sık kullanılan yöntemlerden biri olmuştur.

Wieland vd., sel vb. acil durumlarda taşan suyu kalıcı sudan ayırt etmek için su ve kara sınıflarının kısa bir süre içinde bölütlenmesi amacıyla bir çalışma gerçekleştirmişler. Bu amaçla LANDSAT ETM+, TM, OLI ve SENTINEL-2 uydularının kırmızı, yeşil, mavi, yakın kızılötesi ve kısa dalga kızılötesi bant kombinasyonuna sahip görüntülerini kullanmışlardır. Yaptıkları uygulamada Konvolüsyonel Sinir Ağları'ndan (Convolution Neural Networks – CNN) biri olan U-Net mimarisini kullanmışlardır ve kara, su, buz, bulut ve gölge sınıflarını bölütlemişlerdir. Sunulan çalışma sonuçlarına bakıldığında ortalama doğruluğun %93 olarak elde edildiği ve çalışma amacı için U-Net mimarisinin doğru sonuçlar ürettiği gözlenmektedir [11].

Yapılan bir diğer çalışmada Syrris vd., SENTINEL-2 uydusunun kırmızı, yeşil, mavi ve yakın kızılötesi bant kombinasyonuna sahip görüntüleri ve farklı Konvolüsyonel Sinir Ağları'nı kara, su, bina, orman ve yeşil alanları bölütlemek için kullanmışlardır. Farklı Konvolüsyonel Sinir Ağları olarak U-Net, SegNet, Fully Convolutional Network (FCN) ve standart CNN modelleri tercih etmişlerdir. Eğitim işlemi ve doğruluk değerlendirmesi için her bir modelde farklı veri girdi boyutları, 122x122, 244x244, 366x366, kullanmışlardır. Her bir model farklı boyutlardaki veri boyutu ile eğitilmesi sonucunda en yüksek ortalama doğruluk değeri olan %85'e 244x244 veri boyutu ve U-Net mimarisi kullanılarak ulaşmışlardır [12].

Liu vd., uzaktan algılama görüntülerinden kıyı çizgisinin çıkartılması için yeni bir Konvolüsyonel Sinir Ağı yapısı önermişlerdir. Standart bir Konvolüsyonel Sinir Ağı'nda bulunan konvolüsyon katmanını Mini-Inception yapısı ile değiştirmişlerdir ve aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) yerine leaky-ReLU aktivasyon fonksiyonunu kullanmışlardır. Önerilen yeni sinir ağı Qingdao'daki Jiaozhou Körfezi'nin uzaktan algılama görüntüleri üzerinde test edilmiştir. Sunulan çalışma sonuçları, önerilen yöntemin diğer yöntemlere kıyasla bazı avantajları olduğunu, kıyı çizgisi çıkartmanın doğruluğunu artırabileceğini, hesaplama maliyetini ve işlem süresini önemli ölçüde artırmadığını göstermektedir [13].

Yang vd., kara-su bölütlemesi için SSAE (Stacked Sparse Autoencoder) tabanlı derin öğrenme mimarisi kullanmışlardır. Çalışmada bölütleme için LANDSAT uydu görüntüleri kullanılmıştır. Doğruluğu artırmak için her pikselin NDVI, NDWI ve NDBI (Normalize Fark Bina İndeksi - Normalized Difference Built Index) değerleri ile özellik matrisi oluşturulmuştur. Özellik matrislerini genişletmek için komşu pikseller dikkate alınarak Özellik Genişletme Algoritması (Feature Expansion Algorithm - FEA) uygulanmıştır. SSAE derin öğrenme ağına genişletilen özellik haritaları girdi olarak verilmiştir ve bölütleme işlemi için eğitilmiştir. Destek Vektör Makinesi ve klasik Yapay Sinir Ağı'na göre önerilen model daha iyi performans sergilemiştir. Özellik Genişletme Algoritması, su sınıfının farklı özelliklerini ortaya çıkardığından bölütleme doğruluğunu büyük ölçüde artırmıştır [14].

Erdem vd., su sınıfının çıkarılması için WaterNet adında 5 farklı derin öğrenme modelinin kombinasyonu içeren bir yöntem geliştirmişlerdir. Bu amaçla yaptıkları çalışmada Standard U-Net, Dilated U-Net, Fractal U-Net, FC-DenseNet ve Pix2Pix gibi farklı derin öğrenme mimarileri ve LANDSAT-8 uydusunun kırmızı-yeşil-mavi-yakın kızılötesi bantlarına sahip görüntüleri kullanılmıştır. Önerilen model diğer derin öğrenme modelleri ve AWEI ile karşılaştırıldığında tutarlı sonuçlar vermiştir, IoU ve F1 skorları WaterNet için %99,59 ve %99,79 olarak hesaplanmıştır. Çalışma sonuçlarına göre, WaterNet yönteminin LANDSAT-8 OLI uydu görüntülerinden kıyı çizgisi çıkarımı açısından diğer yöntemlerden daha iyi performans sergilediğini göstermektedir [15].

Geleneksel makine öğrenmesi algoritmalarında her bir görev ayrı ayrı değerlendirip en baştan öğrenme gerçekleştirilir. Bazı görevlerden öğrenilen bilgileri başka görevlerde de kullanmak veri seti hazırlamak açısından kolaylık sağlamaktadır. Bu sebeple aktarımlı öğrenme ile kaynak görevlerden elde edilen bilgi hedef görevin çözümü için kullanılmaktadır. Öğrenme aktarımı ile daha önceden eğitilmiş modellerden elde edilen özellikler, ağırlıklar yeni bir görev için kullanılmaktadır [16].

Turizm ve balıkçılık alanlarının, geçim kaynağı deniz kıyılarının sağlığına bağlıdır. Bu amaçla Nazerdeylami vd., sahil şeridinde nesne tespiti için önceden eğitilmiş

model olarak Derin Sinir Ağları'ndan (DNN) biri olan VGG mimarisi kullanmışlardır ve aktarımlı öğrenme işlemi gerçekleştirmişlerdir. Sonuçlar, sunulan tekniğin doğruluğunun sahil şeridinde nesne tespiti için kabul edilebilir olduğunu göstermektedir [17].

## 1.2 Tezin Amacı

Petrol-gaz kaynakları, mineral kaynakları, gelgit-dalga enerji kaynakları ve diğer yenilenebilir enerji kaynakları açısından kıyı alanları dünyanın en yoğun nüfuslu bölgeleri haline gelmiştir ve nüfus artış hızı zamanla istikrarlı bir şekilde artmaktadır [1]. Kıyı alanları, insan etkileri ve doğal sebeplerden kaynaklanan dinamik değişikliklerin olduğu, ekonomik ve sosyal açıdan nitelikli bölgelerdir [18]. Doğal ve antropojenik etkilerle meydana gelen değişiklikleri tespit etmek için kıyı alanlarının izlenmesi gerekmektedir. Kıyı alanlarındaki değişimlerin sürdürülebilir bir şekilde izlenmesi, kıyı kaynak yönetimi, çevresel koruma ve planlama açısından oldukça önemli rol oynamaktadır. Kıyı çizgisinde meydana gelen değişimlerin hızlı ve doğru bir şekilde belirlenmesi sadece kıyı ıslahı, kentsel büyüme ve liman geliştirme faaliyetleri için değil aynı zamanda denizcilik ekonomisi ve denizcilik araştırmaları için de önemli bir konudur [1].

Uydu görüntüleri ile kıyı çizgisi çıkarmada yarı otomatik yöntemlerin yanı sıra makine öğrenmesi ve derin öğrenme yöntemleri de sıklıkla tercih edilmektedir. Yapılan tez çalışmasında derin öğrenme modellerinin uygulanmasında yaygın olarak kullanılan aktarımlı öğrenme (transfer learning) yönteminin kıyı çizgisi çıkarılmasındaki başarısının incelenmesi amaçlanmıştır.

## 1.3 Hipotez

Sunulan tez çalışması; "LANDSAT-8 uydu görüntüleri ile eğitilmiş U-Net mimarisinin ağırlıkları ve az sayıda SENTINEL-2 uydu görüntüsü veri seti kullanılarak aktarımlı öğrenme ile yüksek doğrulukta kıyı çizgisi çıkartmak mümkündür" hipotezi üzerine kurulmuştur.

### 2.1 Kıyı Çizgisine Ait Tanımlar

Dolan vd., tarafından kıyı çizgisi, “kara ve su arasındaki fiziksel ara yüzey” olarak tanımlanırken Gens tarafından “kara-su arasındaki anlık çizgi” olarak tanımlanmaktadır [19].

Ülkemizde kıyı bölgeleri için oluşturulan ve günümüze dek yürürlükte olan 3621 Sayılı Kıyı Kanunu ve bu kanundaki bazı maddelerde değişikliğe gidilmesine dair 3830 Sayılı Kıyı Kanunu’na göre kıyı ile ilgili tanımlamalar aşağıdaki şekildedir [20]:

“Kıyı çizgisi: Suni ve doğal göl, deniz ve akarsularda taşkın durumları dışında suyun karaya değdiği noktaların birleşmesinden oluşan çizgiyi,

Kıyı Kenar çizgisi: Suni ve doğal göl, deniz ve akarsularda, kıyı özelliği bulunduran bölgelerinde kıyı çizgisinden sonraki kara yönünde su hareketlerinin oluşturduğu doğal sınırı,

Kıyı: Suni ve doğal göl, deniz ve akarsularda kıyı çizgisi ve kıyı çizgisinden sonraki kara yönünde su hareketlerinin oluşturduğu doğal çizgi arasındaki alanı,

Sahil şeridi: Suni ve doğal göl, denizlerin kıyı kenar çizgisinden itibaren kara yönünde yatay olarak en az 100 metre genişliğindeki alanı,

Dar Kıyı: Kıyı çizgisi ile kıyı kenar çizgisinin çakışmasını ifade eder.”


Şekil 2.1’de Kıyı Kanunu’nda bulunan tanımlar gösterilmektedir.



Şekil 2.1 Kıyı Kanunu'na göre kıyı ile ilgili tanımları gösteren kroki [20]

## 2.2 Kıyı Çizgisinin İzlenmesinin Önemi

Kıyı bölgelerinde artan nüfusla birlikte, kıyı değişiminin incelenmesi araştırmacıların en önem verdiği konulardan biridir. Kıyı alanları, insan etkileri ve doğal sebeplerden kaynaklanan dinamik değişiklerin olduğu ekonomik ve sosyal açıdan nitelikli bölgelerdir [18]. Kıyı çizgileri küresel ısınma, nüfus artışı, çevre kirliliği, kentleşme etkileriyle sürekli değişir. 2.2'de Atlantik Okyanusu'na ait örnek bir bölgede kıyı çizgisinin yıllar içinde değişimi gösterilmiştir.



**Şekil 2.2** Kıyı çizgisinin yıllar içinde değişimi [22]

Doğal ve insani etkilerle meydana gelen değişiklikleri tespit etmek için kıyı alanlarının izlenmesi gerekmektedir. Kıyı çizgisinin konumunun ve bu çizginin zamanla değişen konumu kıyı bilim insanları, mühendisler ve yöneticiler için kıyı yönetimi, mühendislik çalışmaları, kıyı kaynak yönetimi çalışmalarını gerçekleştirebilmeleri açısından önemli bir konudur [18]. Kıyı çizgisinde meydana gelen değişimlerin hızlı ve doğru bir şekilde belirlenmesi sadece kıyı ıslahı, kentsel büyüme ve liman geliştirme faaliyetleri için değil aynı zamanda denizcilik ekonomisi ve denizcilik araştırmaları için de önemli bir konudur [1].

Kıyı erozyonu, kumsalların azalmasına neden olmaktadır ve bu sebeple kıyı boyunca uzanan deniz duvarları ve yollar dalgaların neden olduğu hasarlara karşı daha savunmasız hale gelmektedir. Kıyı erozyonu, kıyı çizgisinde değişiklikler olarak kendini göstermektedir bu nedenle kıyı erozyonuna neden olan faktörlerin belirlenmesi ve bu duruma karşı önlemlerin alınması için kıyı çizgilerinin izlenmesi daha önemli hale gelmektedir [23].

Kıyı çizgisi değişimleri hakkında doğru ve güncel bilgiler, erozyon birikimi yönleri, kıyı savunma tasarımı, kıyı çizgisinin gelecekteki konumlarının tahmini, tehlike

bölgeleri, çevre koruma, güvenli navigasyon ve sürdürülebilirlik gibi çok çeşitli kıyı araştırmalarında yardımcı olmaktadır [24].

Kıyı alanlarındaki nüfus artışı, iklim değişikliği, deniz seviyesinin yükselmesi vb. etkilerle yaşanan çevre sorunları gelecekte kaçınılmaz olarak daha da artacaktır. Doğal tehlikelerin etkilerinin hafifletilmesi, büyük ölçekli sosyal felaketlerin önlenmesi ve özellikle hasar yaratan olaylar hızlı ve iyi koordine edilmiş çözümler gerektirmektedir. Bu tür bir çözüm için en önemli dayanak, dünyanın farklı kıyı bölgelerinin özel gereksinimlerine uyarlanmış entegre kıyı bölgesi yönetim planlarıdır. Bu da kıyı çizgilerinin izlenmesinden geçmektedir [25].

### **2.3 Kıyı Çizgisi Çıkarımında Uzaktan Algılama**

Uzaktan algılama, herhangi bir temas olmadan bir bölgenin veya nesnenin fiziksel özelliklerini tespit etmek için karadan, atmosferden ve su ekosistemlerinden yayılan ve yansıyan enerjinin algılanması teknolojisidir. Uzaktan algılama ile veri toplama, pasif veya aktif sensörler olarak sınıflandırılan uçak tabanlı ve uydu tabanlı sensör teknolojilerini içermektedir. Pasif uzaktan algılama ile ölçülen en yaygın enerji kaynağı güneş ışığıdır. Aktif sensörler nesnelere ve alanları taramak için kendi enerjilerini kullanmaktadır. Toplanan uzaktan algılama verileri donanımlar ve yazılımlar kullanılarak işlenir ve analiz edilir [26].

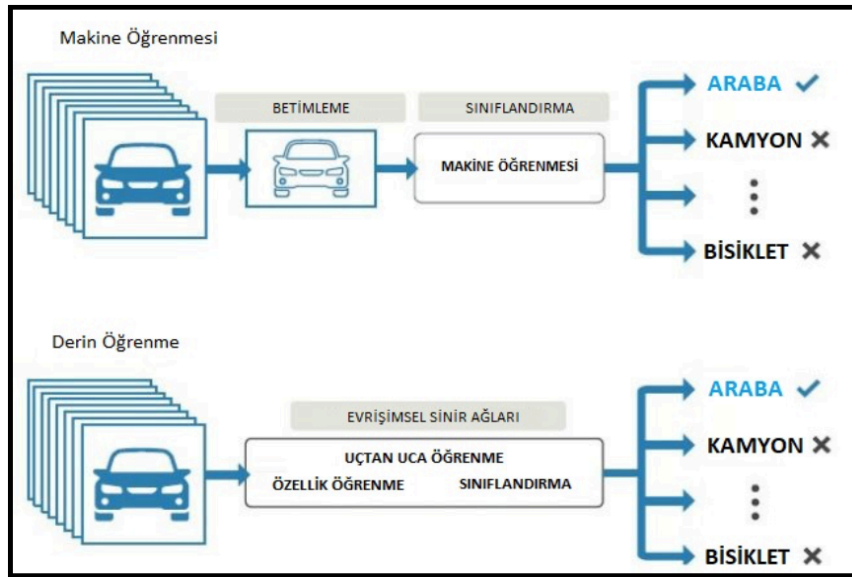
Kıyı çizgisini çıkartmak ve kıyı alanlarını izlemek için fotogrametrik yöntemler, uzaktan algılama, yersel ölçüler ve GPS teknolojisi verileri kullanılabilir [1]. 1972'de LANDSAT uydusunun kullanılmaya başlanılmasından itibaren uzaktan algılama verileri diğer yöntemlerden elde edilen verilere alternatif haline gelmiştir. Yersel ölçülere göre uydu görüntüleri, kıyı çizgisi izleme için anlık ve güncel verilerin toplanmasını sağlamaktadır [2].

Kıyı çizgisinde meydana gelen değişimler hakkındaki doğru ve güncel bilgiler, kıyı kaynak yönetimi, gelecekteki kıyı çizgisi konum tahmini, erozyon yönü, çevre koruma, güvenli navigasyon ve sürdürülebilir kıyı gibi çok çeşitli kıyı araştırmaları konusunda yardımcı olmaktadır [27].

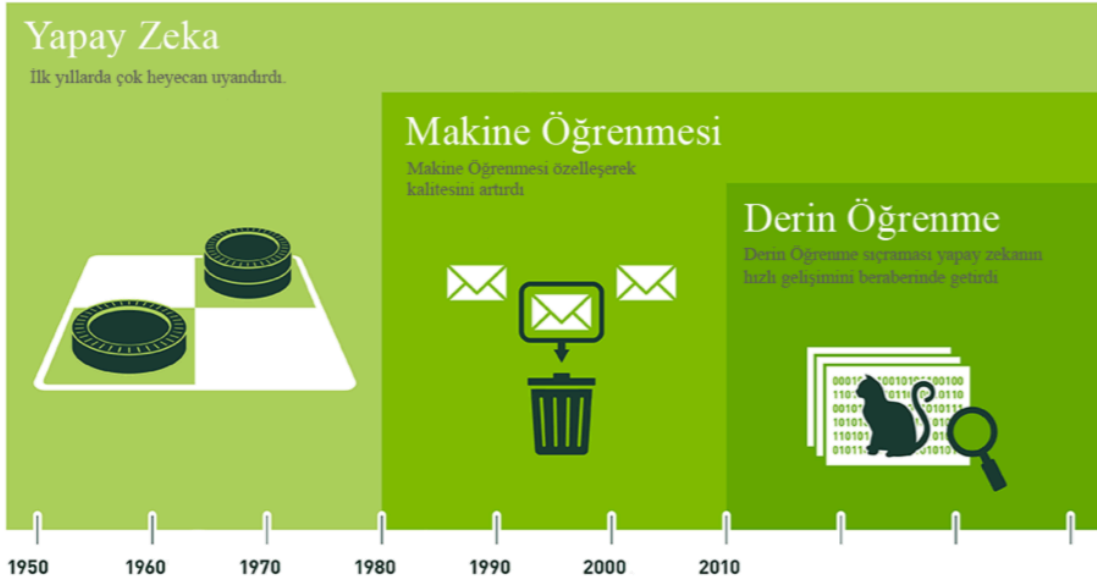
### 3.1 Derin Öğrenme

Derin öğrenme Goodfellow vd., tarafından bilgisayarların dünyayı öğrenmesi ve insanlara benzer şekilde karar vermesini sağlayan makine öğrenmesinin bir yöntemi şeklinde tanımlanmaktadır [28].

Derin öğrenme yöntemin makine öğrenmesi yöntemine göre en önemli üstünlüğü özellik çıkartma işlemini kendi kendine, otomatik bir şekilde yapabilmesidir [10]. Özellik çıkartma, bilgisayarın öğrenmesi için kullanılan veri setini betimleyen tanımlayıcıların belirlenmesidir. Klasik makine öğrenmesinde özellik çıkartma işlemi kullanıcı tarafından manuel olarak gerçekleştirilmektedir bu durumda kullanıcının çıkarılacak olan özelliklere karar verebilmesi için veri setini uzun bir süre boyunca analiz etmelidir. Ancak derin öğrenmede özellik çıkartma işlemi otomatik gerçekleştiği için analiz etme süresi büyük ölçüde kısalmaktadır (Şekil 3.1). Şekil 3.2’de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki gösterilmektedir.



Şekil 3.1 Derin öğrenme ve klasik makine öğrenmesi [29]




**Şekil 3.2** Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi ve kronolojisi [30]

Derin öğrenme; endüstri, tıp, robotik, görüntü işleme, obje tespiti, ses tanıma, görüntü tanıma, görüntü bölütleme, gelecek tahmini, ses işleme-tanıma, çeviri gibi farklı alanlarda çözümler üretmektedir [28].


### 3.2 Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks – CNN) ızgara (grid) yapısına sahip verileri işlemek için kullanılır. Konvolüsyonel Sinir Ağları, pratik uygulamalarda başarılı olmuştur [28]. Konvolüsyonel Sinir Ağları'nın amacı, verilerdeki özellikleri konvolüsyon işlemleriyle öğrenmektir. Konvolüsyonel Sinir Ağları görüntü tanıma uygulamaları için uygun ve ideal bir yöntemdir. Şekil 3.3'te düşük, orta ve yüksek seviyeli özellik çıkarımına ait örnek gösterilmektedir [10].



**Şekil 3.3** Düşük, orta ve yüksek seviyeli özellikler [31]

Konvolüsyonel Sinir Ağları farklı işlemlere sahip bileşenlerin peş peşe sıralanması ile meydana gelmektedir. Bu bileşenler girdi, konvolüsyon katmanı, aktivasyon fonksiyonu, havuzlama ve tam bağlı katman olarak isimlendirilmektedir. Şekil 3.4'de Konvolüsyonel Sinir Ağı yapısı gösterilmektedir.



**Şekil 3.4** Konvolüsyonel Sinir Ağı yapısı [32]

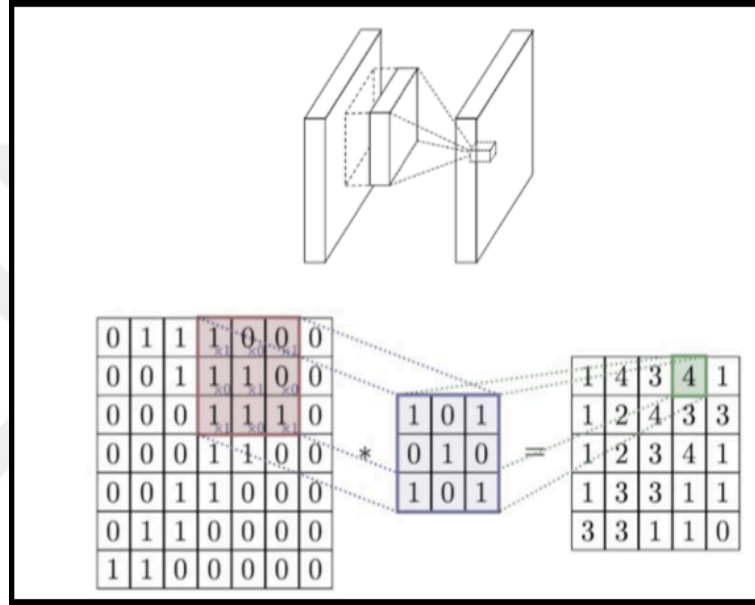
### 3.2.1 Girdi Katmanı (Input Layer)

KSA'nın ilk katmanını oluşturan girdi katmanı, görüntü metin bilgisi, farklı ölçülere ilişkin bilgiler gibi farklı veriler olabilmektedir. Örneğin üç bant içeren bir görüntüye ait RGB (Kırmızı-Yeşil-Mavi) verileri girdi verisi olarak alındığında girdi katman derinliği 3 olmaktadır [10]. Ayrıca modelin başarılı olması için girdi katmanındaki veri boyutu önemlidir. Girdi veri boyutunun yüksek belirlenmesi eğitim süresini uzatabilmekte ve yüksek bellek ihtiyacı doğurabilmektedir. Ancak bunun yanı sıra ağ başarısını artırabilmektedir. Girdi veri boyutunun düşük belirlenmesi belleğe olan ihtiyacı azaltır, eğitim süresini kısaltır. Bu sebepler, ağ derinliği ve kullanılacak olan donanım ve ağ başarısı dikkate alındığında uygun bir girdi veri boyutu seçilmelidir [36].

### 3.2.2 Konvolüsyon Katmanı (Convolutional Layer)

Bu katman Konvolüsyonel Sinir Ağları'nın temelini oluşturmaktadır. Konvolüsyon katmanının girdi verisi bir başka konvolüsyon katmanının çıktısı veya ham veri olabilmektedir. Konvolüsyon katmanında özellik çıkartma işlemi gerçekleşmektedir. Bu işlem, çekirdek matris ile belirli bir filtrenin girdi verileri üzerindeki özellikleri çıkartması işlemine dayanmaktadır. Bu filtreler mimarinin ayrılmaz bir parçasıdır. Filtreler 2x2, 3x3, 5x5 gibi çeşitli boyutlarda olabilmektedir. Konvolüsyon işlemi sonucunda girdi verilerine ait özellik haritaları


oluşturulmaktadır. Örneğin: girdi verileri 5x5 boyutunda bir RGB görüntüsü olarak varsayılırsa görüntü üzerinde 3x3 boyutunda bir filtre dolaştırılır. Filtre matris sınırına ulaştığında bir basamak aşağı kaydırılarak işlem devam eder. Filtre matrisindeki her bir değer girdi verisindeki her kanaldaki piksel ile ayrı ayrı çarpılır ve çarpım sonuçları toplanır. Bu hesaplama sonucunda özellik haritası elde edilir. Elde edilen özellik haritasındaki yeni piksel değerleri girdi verisindeki piksel değerlerinden büyük değerler olmaktadır [33]. Şekil 3.5'te özellik haritasının elde edilmesi için uygulanan konvolüsyon işlemine ait örnek sunulmuştur.



Şekil 3.5 Konvolüsyon işlemi [32]

### 3.2.3 Aktivasyon Fonksiyonları (Activation Functions)

Konvolüsyon katmanında matematiksel işlemler uygulandığı için ağ doğrusal yapıdadır, konvolüsyon işlemi sonucunda elde edilen özellik haritasındaki bileşenlere doğrusal olmayan bir yapı kazandırmak için aktivasyon fonksiyonu uygulanır. Kullanımı en sık olan aktivasyon fonksiyonları Hiperbolik Tanjant, Sigmoid ve ReLU fonksiyonlarıdır. Özellik haritasındaki değerler; Sigmoid fonksiyonu ile [0-1] aralığında, Hiperbolik Tanjant fonksiyonu ile [1,-1] aralığında temsil edilmektedir. ReLU fonksiyonu ise özellik haritasındaki negatif değeri sıfır, pozitif değerleri olduğu gibi bir diğer katmana aktarmaktadır [34]. Şekil 3.6'te ReLU, Sigmoid ve Hiperbolik Tanjant fonksiyonlarına ait grafikler ve eşitlikler gösterilmektedir.



**Şekil 3.6** Aktivasyon fonksiyonları[35]

ReLU fonksiyonunun girdi verisine yaptığı etki Şekil 3.7’de gösterilmektedir. Şekil 3.7’de soldaki görüntü girdi görüntüsü, ortadaki konvolüsyon katmanında filtre uygulanması sonucu oluşan görüntü ve sağdaki görüntü ise ReLU katmanından çıkan görüntüyü göstermektedir.




**Şekil 3.7** Aktivasyon fonksiyonlarının özellik haritasına etkisi [36]

### 3.2.4 Havuzlama Katmanları (Pooling Layer)

Verilerin karakteristik özelliklerini ortaya çıkaran havuzlama katmanları hesaplama maliyetini düşürmek için kullanılmaktadır [28].

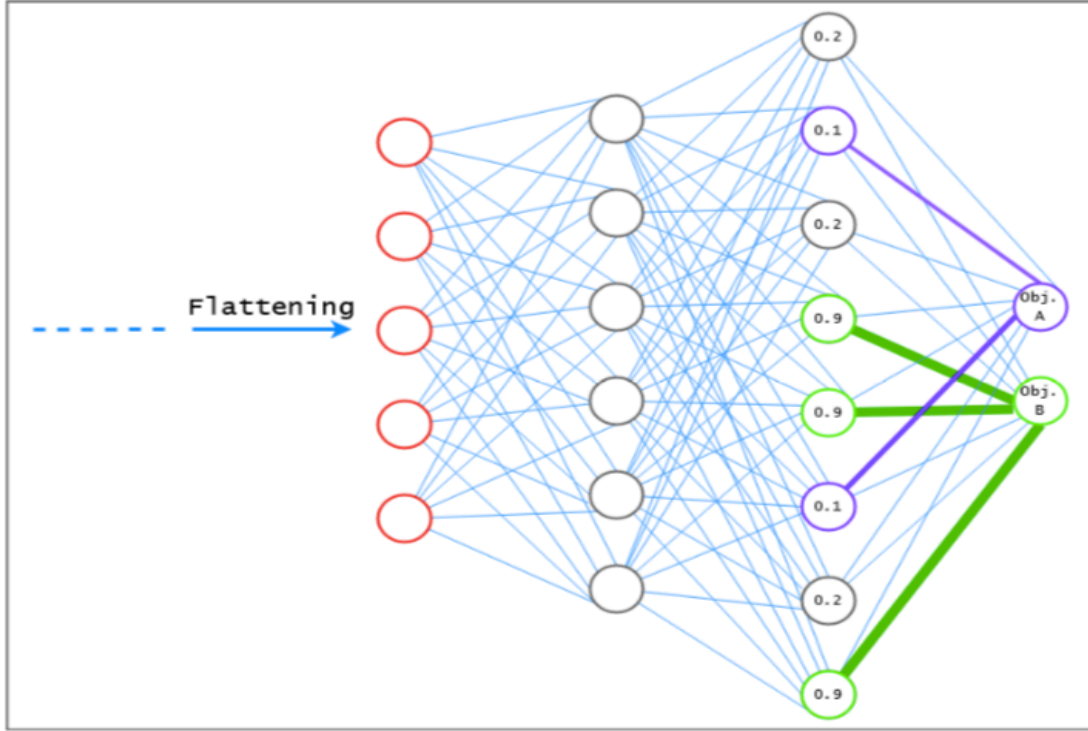
Konvolüsyon katmanlarının çıktısı olan özellik haritalarına havuzlama işlemi uygulanır. Sonraki konvolüsyon katmanı için veri boyunca hareket ettirilen havuzlama penceresi yardımıyla girdi boyutu azaltılır. Bu işlem verinin derinlik boyutunu etkilememektedir. Girdi veriler, tercih edilen havuzlama yöntemine göre diğer katmana aktarılmaktadır [32]. Şekil 3.8’de 2x2 boyutlarındaki bir pencere içerisinde uygulanan maksimum havuzlama işlemi gösterilmektedir.



**Şekil 3.8** Maksimum havuzlama işlemi [32]

### 3.2.5 Tam Bağlı Katman ve Softmax Katmanı (Fully Connected and Softmax Layer)

Tam bağlı katmanlar, bilgisayarla görü için görüntüleri tanımada ve sınıflandırma çok başarılı olduğu kanıtlanmış Konvolüsyonel Sinir Ağları'nın temel bir bileşenidir ve Konvolüsyonel Sinir Ağları'nın son katmanı olarak ağda yer almaktadır. Tam bağlı katmanda bulunan tüm nöronlarının bir önceki katman ile arasında bağ bulunmaktadır. Tam bağlı katman, konvolüsyon katmanı ile belirlenen düşük seviyeli, orta seviyeli ve yüksek seviyeli özelliklere dayanarak KSA'lar sonucunda üretilen sınıf puanlarının hesaplanabilmesi için kullanılmaktadır [10]. Şekil 3.9'da Tam bağlı katman yapısı gösterilmektedir.



**Şekil 3.9** Tam Bağlı Katman [38]

Tam Bağlı Katman sonucunda üretilen değerleri ait oldukları sınıflara yerleştirebilmek için sınıflandırıcılara gereksinim vardır. Etiket tahmini için sınıflandırma katmanı olarak ağda yer alan Softmax katmanı tam bağlı katmandan üretilen girdi verilerini alır ve sınıflandırmak için kullanılmaktadır [37].

### 3.2.6 Konvolüsyonel Sinir Ağları'nda Eğitim Parametreleri

Kullanıcı tarafından seçilen eğitim parametreleri eğitilecek ağın performansına büyük bir ölçüde etki eden değişkenlerdir. Ağın eğitilmesi genelde uzun süren bir işlemdir hatta bazı ağların eğitimi aylar sürmektedir. Eğitim parametreleri ile mümkün olduğunca eğitim süresinin kısaltılması amaçlanmıştır [39]. Bu sebeple eğitim parametrelerinin seçimi yapay sinir ağı için önemli bir adımdır. Eğitim parametreleri: Öğrenme Oranı (learning rate), Başlangıç Ağırlıkları, Epok Sayısı, Düzenleme (regularization) ve küme boyutu (batch size) olmak üzere sıralanabilir.

#### 3.2.6.1 Öğrenme Oranı (Learning Rate)

Öğrenme oranı (learning rate), geri yayılım sırasında üretilen düzeltme miktarına göre ağıdaki parametrelerin ne kadar hızlı yenileneceğini göstermektedir. Öğrenme

oranı yüksek bir deęer alındığı takdirde aęın öğrenmesi kısa sürede gerçekleşebilmekte ancak optimum çözüme yaklaşamayan, tutarsız eğitim sonuçları üretme ihtimali bulunmaktadır. Öğrenme oranı düşük deęer seçilirse öğrenme süresi uzun olabilmekte ve algoritmayı verimsiz hale getirebilmektedir. Öğrenme oranı, bu durumlar göz önünde bulundurularak dięer eğitim parametrelerine ve veri kümesine göre belirlenmektedir [10].

### **3.2.6.2 Epok Sayısı (Epochs)**

Epok sayısı tüm veri setinin aęda kaç defa eğitime dahil olacağını göstermektedir. Epok sayısı problem türüne göre deęişiklik göstermektedir. Epok sayısı artıkça aęın başarısı artmaktadır. Epok sayısı çok yüksek bir deęer seçildiğinde doğruluk belirli bir epoktan sonra çok küçük deęerlerde artış göstereceęi için işlem yükünün artmasına sebep olmaktadır. Epok sayısının düşük deęer seçilmesi öğrenememe (under-fitting) durumuna sebep olabilmektedir [39].

### **3.2.6.3 Küme Boyutu (Batch Size)**

Aę eğitilirken bir epokta tüm veri setinin aynı anda eğitimde kullanılması, veri boyutu ve aę derinlięi göz önüne alındığında hem maliyet hem donanım sorunlarına sebep olmaktadır. Bu sebeple veri seti parçalara bölünmüş halde eğitim aşamasında yer almaktadır. Bir parçada bulunan veri sayısı küme boyutunu belirtmektedir [40].


### **3.2.6.4 Başlangıç Aęırlıkları (Initial Weights)**

Sinir aęlarında nöronlar arasında bulunan aęırlıkların başlangıç deęerlerinin belirlenmesi, ileri besleme ile elde edilecek düzeltme miktarını etkiledięi için eğitim işleminde önemli role sahiptir. Başlangıç aęırlıkları normal dağılım sınırlarında bulunacak şekilde rastgele başlatılabilmektedir [41].

### **3.2.6.5 Düzenleme (Regularization)**

Aşırı öğrenme başka bir isimlendirme ile ezberleme (overfitting), makina öğrenme yöntemlerinde en sık karşılaşılan bir problemdir. Aşırı öğrenme, aęın belirli bir veri setinde yeterli doğrulukta performans sergileyip farklı tür veri setini tahmin ederken başarısız olabilecek analizlerin üretilmesidir [42]. Aşırı öğrenme, algoritmaların veri setini yanlış öğrenmesine ve yanlış sınıflandırma yapmasına

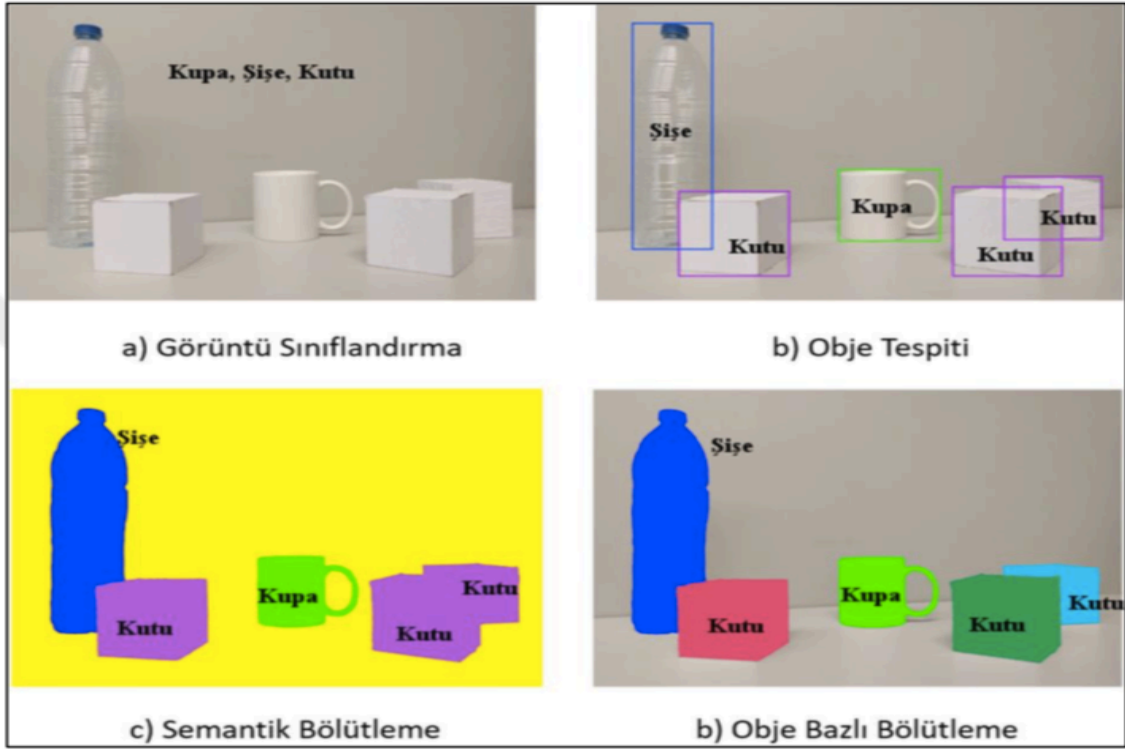
sebeptir. Aşırı öğrenme probleminin başlıca sebebi, veri setinde benzer özelliklere sahip verilerin fazla sayıda bulunmasıdır. Derin öğrenme algoritmalarının, benzer özelliklerin yoğun olduğu veriler ile eğitilmesi ağırlıkların farklı veri türlerini ifade edememesine sebep olmaktadır. Girdi verilerindeki balans problemi sonucunda ortaya çıkabilen bir sonuçtur. Düzenleştirme olarak adlandırılan yöntemler aşırı öğrenme durumunun önüne geçmek için geliştirilmiştir. En sık kullanılan düzenleştirme yöntemi olarak dropout ve L2 yöntemleri tercih edilmektedir [10]. Dropout aşırı öğrenmeyi önlemek için eğitim işlemi aşamasında rastgele seçilen nöronların ağda göz ardı edilmesidir [42]. Şekil 3.10'te Dropout kullanımından önce (sol) ve kullanımdan sonra (sağ) sinir ağını göstermektedir.



Şekil 3.10 Dropout kullanımı [43]

### 3.3 Konvolüsyonel Sinir Ağlarında Semantik Bölütleme

Görüntülerin sınıflandırılması (image classification), semantik bölütleme (semantic segmentation), obje tespiti (object localization) ve obje bazlı bölütleme (instance segmentation) derin öğrenme algoritmalarıyla yapılabilmektedir. Görüntü sınıflandırma, görüntünün hangi nesneyi temsil ettiğini belirleme işlemidir. Semantik bölütleme, görüntüdeki nesnelere temsil eden piksellerin hangi sınıfa ait olduğunu belirlemesidir. Obje tespiti, görüntüdeki objelerin isimleri ve bunun yanında nesnelere ait konum bilgisinin de sınırlayıcı kutular ile belirlenmesidir. Obje bazlı bölütlemeye ise aynı sınıfa ait farklı nesnelere farklı etiketlerle temsil edilmesidir [44]. Şekil 3.11'de görüntü sınıflandırma, semantik bölütleme, obje tespiti ve obje bazlı bölütleme işlemleri görsel ile açıklanmaktadır.



**Şekil 3.11** Derin öğrenme yönteminin görüntü analizinde kullanımı [45]

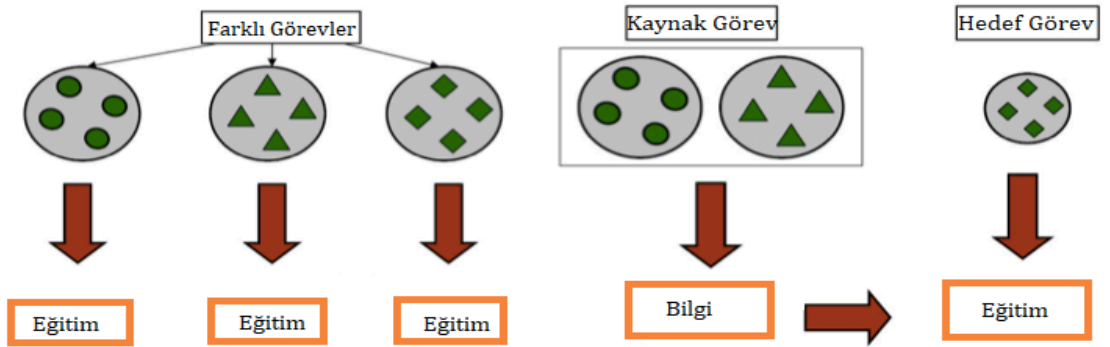
U-Net, SegNet, DeepLab, LinkNet, DenseNet, DilatedNet, PixelNet, Enet, ERFNet semantik bölütleme işlemi yapmak için oluşturulan derin öğrenme mimarilerine örnek olarak verilebilir. Sunulan çalışmada kara-su bölütlemesi için U-Net mimarisi kullanılmıştır.

### 3.3.1 U-Net Mimarisi

U-Net mimarisi, biyomedikal görüntü işleme amacıyla oluşturulmuş olsa da konvolüsyon katmanları içeren ve piksel temelli görüntü bölütleme uygulamalarında az sayıda ve farklı özellikteki veri setlerinde de başarılı sonuçlar vermektedir. U-Net mimarisi kodlayıcı ve kod çözücü olmak üzere iki bölümden oluşmaktadır. Kodlayıcı bölümü iki adet 3x3 boyutundaki konvolüsyon katmanlarında, her konvolüsyon katmanının ardından gelen ReLU aktivasyon fonksiyonundan ve konvolüsyon katmanları arasında geçiş için 2x2 boyutunda maksimum havuzlama katmanlarından oluşmaktadır. Kodlayıcı bölümünü yukarı örnekleme işlemi takip etmektedir. Kod çözücü bölümü, kodlayıcı katmanlarına karşılık gelen 3x3 boyutundaki konvolüsyon katmanlarından ve ReLU aktivasyon fonksiyonundan meydana gelmektedir. Son konvolüsyon katmanında 2 adet 3x3



İnsanlar, benzer olaylar arasında bilgi aktarmanın doğal yollarına sahiptir. Başka bir ifadeyle yeni görevle karşılaştığında önceki öğrenme deneyimlerinden faydalanarak ilgili bilgileri tanımakta ve uygulamaktadır [16]. Aktarımlı öğrenme de, insanların yeni problemleri daha hızlı veya daha iyi yöntemlerle çözmek için daha önce öğrendikleri bilgileri akıllıca uygulayabilmelerine dayanmaktadır. Makine öğrenmesi alanında aktarımlı öğrenmenin temel motivasyonu, önceden öğrenilen bilgileri korumak ve yeniden kullanmaktır. Aktarımlı öğrenme, bilgiyi bir veya daha fazla kaynak görevden çıkarmayı ve bilgiyi bir hedef görevde uygulamayı amaçlamaktadır [47]. Kaynak görev ile yeni hedef görev ne kadar ilgili olursa bilgiyi aktarmak o kadar kolay olmaktadır. Bilgi aktarımını mümkün kılan aktarımlı öğrenme, makine öğrenmesini insan öğrenimi kadar verimli hale getirmeye yönelik ilerlemeyi temsil etmektedir [16]. Şekil 3.13'te geleneksel derin öğrenme (sol) ve aktarımlı öğrenme(sağ) tekniklerinin öğrenme süreçleri arasındaki farkı göstermektedir.



Şekil 3.13 Derin öğrenme ve aktarımlı öğrenme arasındaki eğitim süreçleri [47]

### 3.5 Doğruluk Analizi

Aktarımlı öğrenme ile bölütleme işlemi sonucunda elde edilen ikili görüntülerin ve bu ikili görüntülerden elde edilen kıyı çizgisinin doğruluğu tercih edilen yöntemin başarısını göstermektedir. İlk olarak ikili görüntünün doğruluğunu hesaplamak amacıyla elde edilen ikili görüntü ile referans ikili görüntü karşılaştırılarak her bir test görüntüsü için karşılaştırma matrisi elde edilmiş ve bu matris değerleri kullanılarak doğruluk ölçütleri hesaplanmıştır. İkinci adım olarak mimariden elde

edilen kıyı çizgisi ile referans kıyı çizgisi ve Sayısal Kıyı Çizgisi Analizi Sistemi kullanılarak ortalama hata ve karesel ortalama hata hesaplanmıştır.

### 3.5.1 Karşılaştırma Matrisi

**Tablo 3.1** Karşılaştırma Matrisi

		Referans	
		Pozitif	Negatif
Tahmin	Pozitif	DP	YP
	Negatif	YN	DN

Kara-su bölütlemesinin doğruluk değerlendirmesi için doğruluk (accuracy), duyarlılık(recall), hassasiyet(precision), özgünlük(specifity) ve F1 metrikleri kullanılarak gerçekleştirilmiştir. Hassasiyet; negatif tahminlerin referans doğruluğunu, Duyarlılık; pozitif tahminlerin referans doğruluğu, Özgünlük; pozitif tahmin doğruluğunu, F-Skor ise Duyarlılık ve Hassasiyeti arasındaki ilişkiyi veren ölçütleridir. DP; olumlu ve doğru tahmin edilen, DN; olumsuz ve doğru tahmin edilen, YP; olumlu ve yanlış tahmin edilen, YN; olumsuz ve yanlış tahmin edilen olmak üzere doğruluk metrikleri Eşitlik 3.1'de yer almaktadır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN}$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN}$$

$$\text{Hassasiyet} = \frac{DP}{DP + YP} \quad (3.1)$$


$$\text{Özgünlük} = \frac{DN}{DN + YP}$$

$$F - \text{Skor} = \frac{2 * DP}{2 * DP + YP + YN}$$

### 3.5.2 Sayısal Kıyı Çizgisi Analizi Sistemi

Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu tarafından geliştirilen Sayısal Kıyı Çizgisi Analizi Sistemi (Digital Shoreline Analysis System - DSAS), ArcGIS yazılımının eklentisi olarak ücretsiz çalışmaktadır. DSAS, bir zaman serisi içinde bulunan vektör tabanlı kıyı çizgisi verisinin değişimini hesaplamak amacıyla geliştirilmiştir [49].

Sunulan çalışmada DSAS, elde edilen kıyı çizgisinin doğruluğunu belirlemek amacıyla kullanılmıştır. Bu amaçla elle sayısallaştırılan kıyı çizgisi ve aktarımlı öğrenme yöntemi ile çıkarılan kıyı çizgisi arasında yer alan dik mesafeler DSAS'ın Net Kıyı Çizgisi Hareketi modülü kullanılarak hesaplanmıştır. Şekil 3.15'te DSAS'da kullanılan kesitler, elle sayısallaştırılan referans çizgi ve ölçüm noktaları gösterilmektedir.



Şekil 3.14 DSAS yapısı [45]

Elde edilen kıyı çizgisi ile referans kıyı çizgisi arasında bulunan dik mesafelerin ortalama ve karesel ortalama hataları (3.2) ve (3.3) formülleri yardımıyla hesaplanmıştır.

$$O.H = \frac{1}{n} \sum_{i=1}^n |X_i| \quad (3.2)$$

$$K.O.H = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \quad (3.3)$$

Burada n toplam kesit sayısını,  $X_i$ , elde edilen kıyı çizgisi ile elle sayısallaştırılan kıyı çizgisi arasında kalan dik mesafeyi ifade etmektedir.



### 4.1 Kullanılan Yazılım ve Donanım

Sunulan çalışmada;

Ekran Kartı Sürücüsü: NVIDIA GeForce GTX1080 Ti, 11 GB RAM

İşlemci : Intel® Core™ i7-8700K 3.70GHz İşlemci

Yonga Seti : GeForce GTX 1080Ti

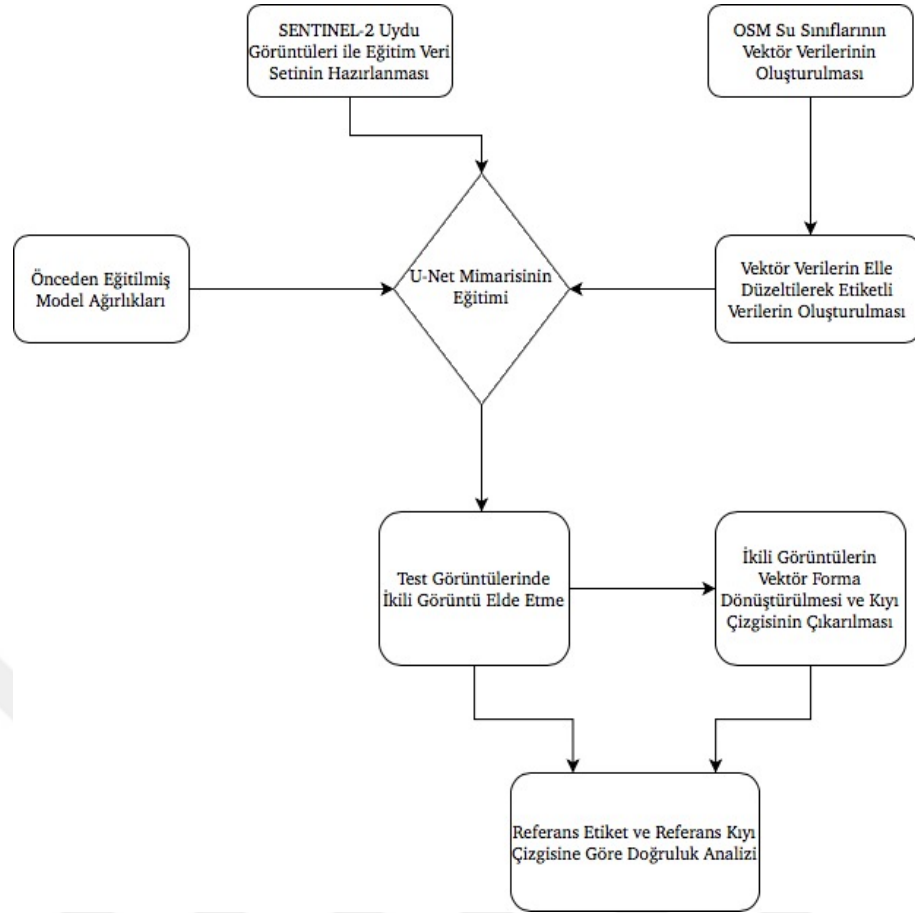
Bellek : 32 GB RAM

teknik özelliklere sahip bilgisayar kullanılarak uygulama gerçekleştirilmiştir.

Çalışmada, eğitim ve test veri setinin hazırlanması işlemleri için QGIS yazılımının 3.2.3 sürümü; aktarımlı öğrenme ve test işlemleri için PYTHON yazılımı; ikili görüntülerden vektör formatta kıyı çizgisi elde etmek için ArcMap 10.3 ve doğruluk analizi için DSAS 4.4 ArcMap eklentisi kullanılmıştır.

### 4.2 Materyal

Tez çalışmasında SENTINEL-2 uydusunun görüntülerinden faydalanılmıştır. Hazırlanan veri setlerinde bölütleme işlemi kara ve su sınıfları oluşacak şekilde gerçekleştirilmiştir. Şekil 4.1'de tez uygulamasının iş akışı gösterilmektedir.



**Şekil 4.1** İş akışı

#### 4.2.1 Veri Seti

Sunulan çalışmada, 10 m konumsal çözünürlüğe ve 15-bit radyometrik çözünürlüğe sahip 2. (mavi), 4. (kırmızı) ve 8. (yakın kızılötesi) bant kombinasyonunu içeren SENTINEL-2 uydu görüntüleri kullanılmıştır. Tablo 4.1’de SENTINEL-2 uydu görüntülerinin teknik özellikleri gösterilmektedir.

**Tablo 4.1** SENTINEL- 2 uydu görüntülerine ilişkin teknik bilgiler [51]


Bantlar	Özellikleri	Merkez Dalga Boyu (nm)
Bant 1	60m Kıyı aerosolü	443
Bant 2	10m Mavi	490
Bant 3	10m Yeşil	560

**Tablo 4.1** SENTINEL- 2 uydu görüntülerine ilişkin teknik bilgiler (devamı)[51]

Bant 4	10m Kırmızı	665
Bant 5	20m Bitki örtüsü	705
Bant 6	20m Bitki örtüsü	740
Bant 7	20m Bitki örtüsü	783
Bant 8	10m Yakın Kızıl Ötesi	842
Bant 8A	20m Daraltılmış Yakın Kızıl Ötesi	865
Bant 9	60m Su buharı	945
Bant 10	60m Kısa Dalga Kızıl Ötesi	1375
Bant 11	20m Kısa Dalga Kızıl Ötesi-1	1610
Bant 12	20m Kısa Dalga Kızıl Ötesi-2	2190

Çalışmada, aktarımlı öğrenme için 15 adet SENTINEL-2 uydu görüntüleri kullanılarak eğitim veri seti ve test veri seti oluşturulmuştur. Veri setini oluşturmak için eğitimde 8 adet görüntü, testte 7 adet görüntü kullanılmıştır. Eğitim veri setinde İzmir, Hatay (2 adet), Kıbrıs, Danimarka (2 adet), İsveç ve Cape


Town kıyılarına ait görüntüler, test verisi için Portekiz, İtalya, Mısır, Finlandiya, Kırım, Amerika Birleşik Devleti ve Riga'ya kıyılarına ait görüntüler kullanılmıştır. Eğitim ve test amacıyla kullanılan görüntülerin konumları Şekil 4.1'de gösterilmektedir.




**Şekil 4.2** Eğitim ve test için kullanılan SENTINEL-2 görüntülerinin konumları Eğitim ve test görüntüleri, denize kıyısı olan, farklı kıyı bölgelerinden ve farklı kıyı tiplerine sahip alanlardan seçilmiştir. Test için kullanılan uydu görüntüleri eğitim görüntüleri dahilindeki görüntüler değildir.

### 4.3 Eğitim Veri Setinin Oluşturulması

Aktarımlı öğrenme ile bölütlemeye eğitim veri seti olarak kullanılmak üzere 512x512 boyutlarında görüntüler ve bu görüntülere ait kara ve su sınıflarını belirten etiket görüntüleri oluşturulmuştur. Veri setini hazırlamak için ilk olarak mavi-kırmızı-yakın kızılötesi bant kombinasyonuna sahip 10980x10980 piksel boyutlarında 8 adet SENTINEL-2 uydu görüntüleri oluşturulmuştur. Şekil 4.2'de eğitim veri seti için hazırlanan uydu görüntüsü gösterilmektedir.



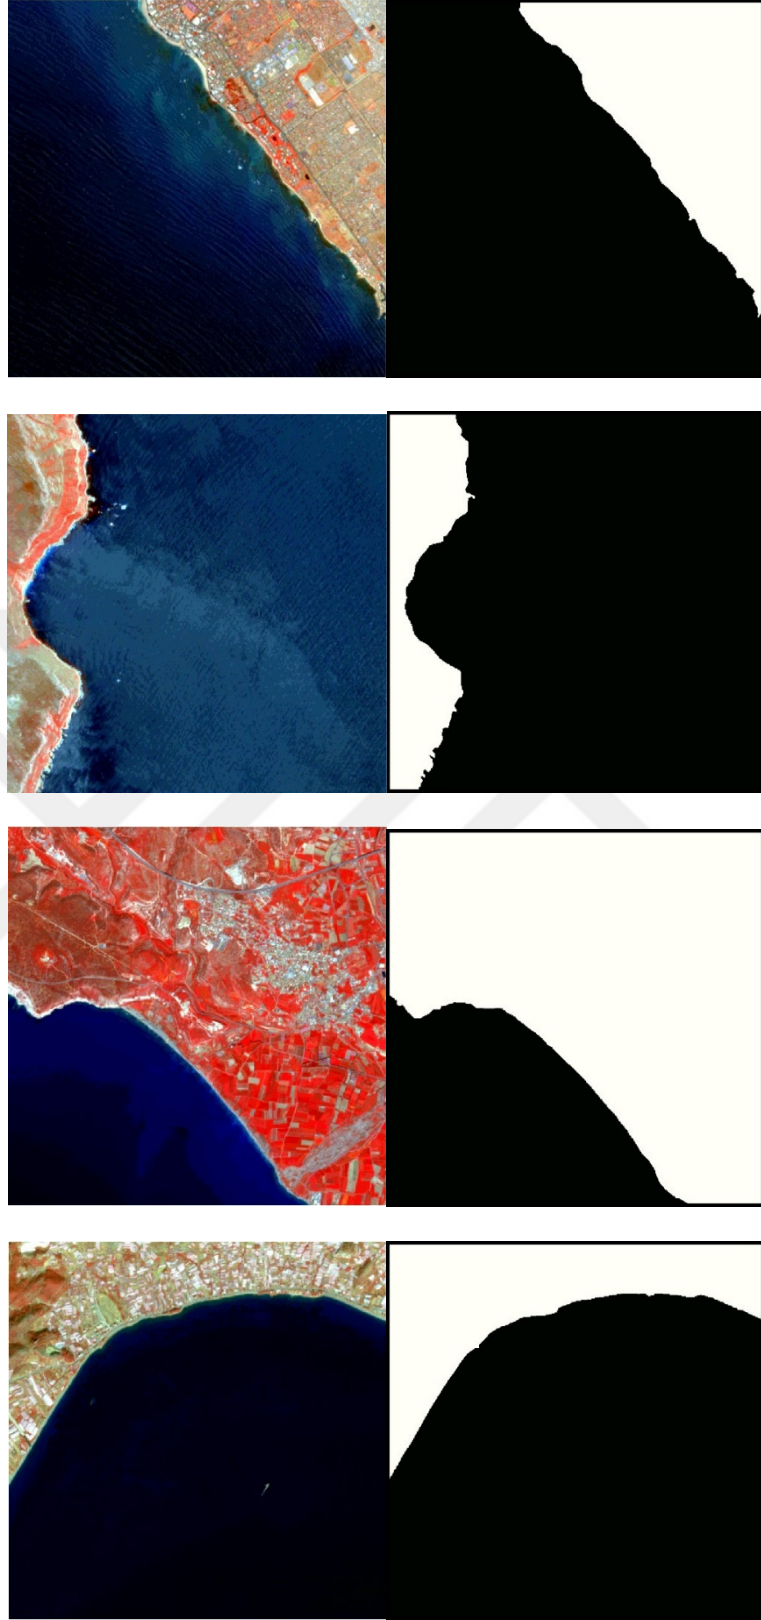
**Şekil 4.3** Eğitim verisinde kullanılan 10980x10980 boyutlarındaki görüntü Aktarımlı öğrenmede eğitim işlemini gerçekleştirebilmek için kullanılacak olan eğitim görüntülerinin su ve kara sınıflarını belirten etiket verilerine ihtiyaç vardır. Eğitim görüntülerinin etiketli verilerini üretmek için ilk olarak OpenStreetMap'ten (OSM) elde edilen su sınıflarının vektör verileri oluşturulmuştur. Oluşturulan vektör veriler üzerinde elle düzeltme ile kara (beyaz) ve su (siyah) sınıflarını belirten ikili görüntüler hazırlanmıştır. Şekil 4.3'de hazırlanan ikili görüntülerden örnek gösterilmektedir.



**Şekil 4.4** Kara ve su sınıflarını gösteren ikili görüntü örneği  
10980x10980 piksel boyutlarındaki SENTINEL-2 eğitim görüntüleri ve etiketli görüntüler parçalara ayırma işlemiyle 512x512 piksel boyutlarında bölünerek alt görüntüler elde edilmiştir. Elde edilen 512x512 boyutlarındaki görüntü setine aşağıdaki işlemler sırayla uygulanmıştır:

- Ağ eğitimini verimsizleştireceği için %99'dan fazla kara ve su sınıfı bulunduran parçalar silinmiştir.
- Mavi-kırmızı-yakın kızılötesi bantları ile oluşturulan görüntülerde bulut gölgelerine ait pikseller ile su sınıfı pikselleri birbirine yakın gri değerlerden oluşmaktadır. Ağın yanlış eğitilmesinin önüne geçmek sebebiyle içinde bulut olan parçalar silinmiştir.
- Son olarak amaç az veri sayısı ile çalışma olduğundan kara ve su sınıflarına ait piksellerin yaklaşık eşit dağılmış görüntüler seçilmiştir.

Bu işlemler sonucunda toplam 115 adet 512 x 512 boyutlarında eğitim verileri elde edilmiştir. Şekil 4.4'te 512 x 512 boyutlarındaki eğitim veri setinden örnekler gösterilmektedir.



Şekil 4.5 512 x 512 boyutlarındaki eğitim veri setinden örnekler



**Şekil 4.5** 512 x 512 boyutlarındaki eğitim veri setinden örnekler(devamı)

#### **4.4 Aktarımlı öğrenme ve U-Net**

Aktarımlı öğrenmede, çoğunlukla önceden eğitilmiş bir modelden elde edilen ağırlık ve özellikler ya doğrudan ya da probleme bağlı olarak eğitilecek ağda öncül veri olarak kullanılır.


Sunulan çalışmada, SENTINEL-2 uydu görüntüleri ile hazırlanmış veri setinden su-kara bölütlerinin elde edilmesi için U-Net mimarisi ile LANDSAT-8 OLI uydusundan alınan Arnavutluk, Arjantin, Bulgaristan, İngiltere, Gürcistan, Yunanistan, İrlanda, İtalya, Libya, Rusya, Güney Afrika ve İspanya, Türkiye ve ABD kıyılarına ait mavi, kırmızı, yakın kızılötesi bant kombinasyonuna sahip görüntüler ile eğitilen U-Net mimarisinin ağırlıkları [15] kullanılmıştır. U-Net mimarisini eğitmek için önceden eğitilen eğitilen U-Net mimarisinin ağırlıkları başlangıç ağırlıkları olarak kullanılmıştır.

Aktarımlı öğrenmede ve U-Net mimarisinde kullanılan parametreler Tablo 4.2'de gösterilmektedir. Eğitim parametrelerinin seçiminde, kullanılan donanımın özellikleri ve önceki çalışmalar dikkate alınmıştır.

**Tablo 4.2** Kullanılan eğitim parametreleri

	Aktarımlı Öğrenme [15]	Sunulan Çalışma U-Net
Eğitim görüntü sayısı (512x512)	824	115
Test görüntü sayısı (512x512)	92	235
Epok Sayısı	100	50
Loss Fonksiyonu	Binary Cross-entropy	Categorical Cross entropy
Aktivasyon Fonksiyonu	ReLU	ReLU
Optimizasyon	Adam	Adadelta
Öğrenme Oranı	0.0002	0.05
Batch Boyutu	1	2
Doğruluk Metriği	Dice Coefficient	Dice Coefficient


Eğitim işlemi yaklaşık 2 saatte tamamlanmıştır. Şekil 4.5'te eğitim veri seti için doğruluk grafiği gösterilmektedir. Doğruluk grafiği incelendiğinde %95 öğrenme doğruluğu düzeyine 10. epoktan itibaren başladığı gözlemlenmektedir.




**Şekil 4.6** Aktarımlı öğrenme eğitimi boyunca elde edilen doğruluklar

#### 4.5 Kıyı Çizgilerinin Elde Edilmesi


LANDSAT-8 görüntüleri ile önceden eğitilen U-Net mimarisinin ağırlıkları ve SENTINEL-2 görüntüleri ile yeniden oluşturulan veri seti ile U-Net mimarisi yeniden bir eğitim işlemi gerçekleştirilmiştir. Yeniden eğitilen ağ 7 adet SENTINEL-2 uydu görüntüsünden hazırlanan 235 adet 512x512 piksel boyutlarında alt görüntüler ile test edilmiştir. Kıyı çizgisi elde etmek için ilk olarak mavi, kırmızı ve yakın kızılötesi bant kombinasyonuna ait görüntülerin ikili görüntüleri elde edilmiştir. Test görüntülerden elde edilen ikili görüntüler Şekil 4.7, Şekil 4.8, Şekil 4.9, Şekil 4.10, Şekil 4.11, Şekil 4.12 ve Şekil 4.13'te gösterilmektedir.




**Şekil 4.7** Portekiz test görüntüsü için ikili görüntü



Şekil 4.8 İtalya test görüntüsü için ikili görüntü




Şekil 4.9 Mısır test görüntüsü için ikili görüntü




Şekil 4.10 Finlandiya test görüntüsü için ikili görüntü



Şekil 4.11 Kırm test görüntüsü için ikili görüntü




**Şekil 4.12** ABD test görüntüsü için ikili görüntü




**Şekil 4.13** Riga test görüntüsü için ikili görüntü

U-Net mimarisinden elde edilen ikili görüntüler kıyı çizgisi çıkartmak amacıyla ArcMap ortamına aktarılarak vektör formata dönüştürülmüştür. Yapılan vektörleştirme işlemiyle elde edilen kıyı çizgileri Şekil 4.14, Şekil 4.15, Şekil 4.16 ve Şekil 4.17’de gösterilmektedir.




**Şekil 4.14** Portekiz(sol) ve İtalya(sağ) test görüntüleri için çıkartılan kıyı çizgileri



**Şekil 4.15** Mısır(sol) ve Finlandiya (sağ) test görüntüleri için çıkartılan kıyı çizgileri



**Şekil 4.16** Kırım (sol) ve ABD (sağ) test görüntüleri için çıkartılan kıyı çizgileri



**Şekil 4.17** Riga test görüntüsü için çıkartılan kıyı çizgileri

## 4.6 Doğruluk Analizi

Doğruluk analizi için Sayısal Kıyı Çizgisi Analizi Sistemi (DSAS) ve hata matrisi kullanılmıştır.

### 4.6.1 Karşılaştırma Matrisi

Karşılaştırma matrisi ile doğruluk analizi yapabilmek için gerekli olan referans ikili görüntü manuel olarak oluşturulmuştur. Elde edilen ikili görüntü ile referans ikili görüntü karşılaştırılarak her bir test görüntüsü için doğruluk değerlendirmesi yapılabilmektedir. Kıyı şeridi bölütlemesinin doğruluk değerlendirmesi için doğruluk, duyarlılık, hassasiyet, özgünlük ve F1 metrikleri kullanılarak gerçekleştirilmiştir.

Referans ikili görüntü ile sunulan yaklaşımın uygulanması sonucunda elde edilen ikili görüntü karşılaştırılarak elde edilen doğruluk sonuçları Tablo 4.3'te verilmektedir. Tablo 4.3'teki değerlerden de görülebileceği üzere; doğruluk değeri 0.9976, Duyarlılık değeri 0.9979, Hassasiyet değeri 0.9979, Özgünlük değeri 0.9973 ve F- Skor değeri %99,79 oranına ulaşmıştır.

**Tablo 4.3** Test görüntüleri için karşılaştırma matrisi doğrulukları


Görüntüler	Doğruluk	Duyarlılık	Hassasiyet	Özgünlük	F-Skor
Portekiz	0.9880	0.9896	0.9866	0.9865	0.9881
İtalya	0.9970	0.9981	0.9957	0.9956	0.9969
Mısır	0.9950	0.9963	0.9935	0.9934	0.9949
Finlandiya	0.9797	0.9797	0.9797	0.9797	0.9797
Kırım	0.9881	0.9896	0.9866	0.9865	0.9881
ABD	0.9966	0.9977	0.9956	0.9956	0.9966
Riga	0.9976	0.9979	0.9979	0.9973	0.9979

En düşük F-Skor değeri 0.9797 ile Finlandiya test görüntüsüne aittir. Bunun sebebinin kıyı morfolojisinde ani ve sık değişimlerin olması ve kıyıya yakın çok sayıda ve farklı boyutlarda adaların bulunmasından kaynaklandığı düşünülmektedir. Aynı şekilde Kırım'a ait test görüntüsünde de limanların bulunduğu alanlarda ani ve sık değişimlerin olması doğruluk ölçütlerinde %1.19 oranında bir düşüşe sebep olduğu görülmüştür. Ayrıca kıyı morfolojisinde ani ve sık değişimler olmamasına rağmen dalga etkisi bulunan görüntülerde (Portekiz) doğruluk ölçütlerinde %1.2 oranında düşüş olduğu gözlenmiştir.

Çalışmada kullanılan eğitim ve test veri setlerine bakıldığında (115'i eğitim, 235'i test) test verisi sayısının eğitim verisinden fazla olduğu görülmektedir. Bu da kıyı çizgisi bölütlemesinde aktarımlı öğrenmede az sayıda eğitim veri seti ile yüksek doğrulukta sonuçlar üretilebileceğini göstermektedir.

#### **4.6.2 Sayısal Kıyı Çizgisi Analizi Sistemi**

Sayısal Kıyı Çizgisi Analizi için her bir test görüntüsü için elde edilen kıyı çizgileri ile elle sayısallaştırılan kıyı çizgileri karşılaştırılmıştır. Ana hat (baseline) çizgisini oluşturmak için elle sayısallaştırılan kıyı çizgilerine 500 metre mesafe alınarak tampon (buffer) uygulanmıştır. Başlangıç noktaları ana hat olacak şekilde 50 metrede bir elle sayısallaştırılan ve U-Net mimarisinden alınan kıyı çizgilerine dik kesit çizgileri oluşturulmuştur. Kesit çizgilerinin boyları 900 m olarak seçilmiştir. Şekil 4.20'da ana hat, kesitler, elle sayısallaştırılan kıyı çizgisi ve U-Net mimarisi ile elde edilen kıyı çizgisi gösterilmektedir.



**Şekil 4.18** DSAS elemanları

U-Net mimarisi ile edilen kıyı çizgisi ile elle sayılaşdırılan kıyı çizgisi arasında oluşan dik mesafeleri hesaplamak için DSAS'ın Net Kıyı Çizgisi Hareketi (Net Shoreline Movement - NSM) modülü kullanılmıştır. Ortalama hatalar dik mesafeler kullanılarak hesaplanmıştır. Hesaplanan ortalama hata değerleri Tablo 4.4'te gösterilmektedir.

**Tablo 4.4** U-Net ağı için ortalama hata değerleri

Test Görüntüsü	Ortalama Hata (m)	Ortalama Hata (piksel)	Karesel Ortalama Hata (m)	Karesel Ortalama Hata (piksel)
Portekiz	7.09	0.71	9.15	0.91
İtalya	5.42	0.54	9.77	0.98
Mısır	7.65	0.76	10.45	1.04
Finlandiya	8.02	0.80	13.43	1.3

**Tablo 4.4** U-Net ağı için ortalama hata değerleri(devamı)

Kırım	5.70	0.57	7.93	0.79
ABD	3.40	0.31	6.01	0.60
Riga	3.65	0.36	6.91	0.69

U-Net mimarisinin başarısını değerlendirmek amacıyla kullanılan 7 farklı test görüntüsünden çıkarılan kıyı çizgilerinin ortalama hata değerleri Portekiz için 7.09 m, İtalya için 5.42 m, Mısır için 7.65 m, Finlandiya için 8.02 m, Kırım için 5.7 m, ABD için 3.40 m ve Riga için 3.65 m olarak elde edilmiştir. Benzer şekilde karesel ortalama hatalar Portekiz için 9.15 m, İtalya için 9.77 m, Mısır için 10.45 m, Finlandiya için 13.43 m, Kırım için 7.93 m, ABD için 6.01 m ve Riga için 6.91 m olarak elde edilmiştir. Mısır ve Finlandiya'ya ait test görüntüleri hariç elde edilen karesel ortalama hata değerleri 1 piksel boyutundan az olduğu görülmektedir.

En yüksek ortalama hata değerine 8.02 m ile Finlandiya'ya ait olduğu görülmektedir. Finlandiya kıyı morfolojisinin ani ve sık değişimlere sahip olması, kıyıya yakın çok sayıda çeşitli boyutlarda adalar bulunması ortalama hata değerini artırmaktadır. Diğer ortalama hatalar incelendiğinde Portekiz'de sık değişimlerin olmamasına rağmen dalga etkisinin bulunması da hatayı artırdığı görülmektedir. Ek olarak Mısır görüntüsünün diğer eğitim ve test görüntülerinden farklı yansıma değerlere sahip olması ortalama hatayı artırdığı düşünülmektedir. Eğitim veri setinde veri sayısı aynı olacak şekilde yukarıdaki özelliklere sahip görüntülerle veri çeşitliliği artırılırsa daha da verimli sonuçlar alınacağı öngörülmektedir.

Derin öğrenme uygulamaların gerçekleştirmek için gerekli olan eğitim verilerini ve etiketlerini oluşturmak oldukça maliyetli, zaman alıcı ve fazla insan gücü gerektiren bir işlemdir. Öte yandan yeterli sayıda etiketli hazır veri seti temin etmek bazı uygulamalarda zor olabilmektedir. Bu sebeple sunulan tez çalışmasında aralarında benzerlik ve ilişki bulunan görevleri birbirlerinden bağımsız bir şekilde değerlendirip her görev için çok sayıda eğitim veri setleri hazırlamak ve ayrı ayrı eğitim işlemi gerçekleştirmek yerine görevler arasında bilgi aktarımın mümkün olduğu aktarımlı öğrenme yöntemi kullanılmıştır. Uydu görüntüsü ile eğitilmiş bir mimarinin aktarımlı öğrenme ile başka bir uydu görüntüsü için eğitiminin kıyı çizgisi çıkarımındaki performansı araştırılmıştır. Bu amaç doğrultusunda U-Net derin öğrenme mimarisi önceden eğitilmiş model olarak seçilmiştir ve seçilen modelin ağırlıkları aktarımlı öğrenme işlemiyle birleştirilerek az sayıdaki veri ile tekrar bir eğitim gerçekleştirilmiştir. Eğitim işleminin ardından 7 farklı SENTINEL-2 uydu görüntüsünden kıyı çizgisi elde edilmiştir.

Çalışmada, ikinci görevi gerçekleştirmek için birinci göreve oranla daha az sayıda veri seti kullanılmıştır. LANDSAT-8 ile eğitilen U-Net mimarisinde eğitim için 824 adet alt görüntü kullanılırken SENTINEL-2 ile yeniden eğitilen U-Net mimarisinde 115 adet alt görüntü kullanılmıştır. Daha az veri seti hazırlayarak maliyet, zaman ve insan gücü azaltılmıştır. Ayrıca çalışmada kullanılan eğitim veri seti (115 adet alt görüntü) ve test veri setleri (235 adet alt görüntü) incelendiğinde test verisinin eğitim verisinden daha fazla olduğu görülmektedir. Bu durum da kıyı çizgisi bölütlemesinde aktarımlı öğrenmede az sayıda eğitim veri seti ile yüksek doğrulukta sonuçlar üretilebileceğini göstermektedir.

Derin öğrenme uygulamalarında eğitim verilerinin etiketlerini oluşturmak oldukça zahmetli ve zaman alıcı bir işlem adıdır. Çalışmada eğitim görüntülerinin etiketleri ve test görüntülerinin referans ikili görüntülerini oluşturmak için OpenStreetMap'ten elde edilen su sınıflarının vektör verileri kullanılmıştır. Bu

vektör veriler üzerinde elle düzeltme yapılarak su ve kara sınıflarını belirten ikili etiket görüntüleri hazırlanmıştır. OpenStreetMap kullanımı etiketleri oluşturmak için harcanan süreyi kısaltmıştır.

Derin öğrenme algoritmaları seçilen eğitim parametreleri ve eğitim veri sayısı sebebiyle eğitim işlemi aşamasında güçlü donanıma ihtiyaç duymaktadır. Ancak sunulan tez çalışmasında az sayıda eğitim veri seti kullanıldığından U-Net eğitim işlemi yaklaşık 2 saatte tamamlanmıştır.

U-Net mimarisinin ve aktarımlı öğrenme yönteminin kıyı çizgisi çıkartmak için başarılı olduğu gözlenmiştir. Tablo 4.3'teki değerlerden de görülebileceği üzere; doğruluk değeri 0.9976, Duyarlılık değeri 0.9979, Hassasiyet değeri 0.9979, Özgünlük değeri 0.9973 ve F- Skor değeri %99,79 oranına ulaşmıştır. Ancak kıyı morfolojisinde ani ve sık değişimlerin olduğu, kıyıya yakın çok sayıda adaların bulunduğu, dalga etkisinin olduğu görüntüler yaklaşık %1 oranında bir düşüş olduğu görülmektedir. Eğitim veri seti içinde çok az sayıda kıyı morfolojisinde ani ve sık değişim içeren alt görüntüler olmasına rağmen bu özelliğe sahip test görüntüsü doğruluğunda düşüş yaşandığı gözlemlenmiştir. Bu özellikteki veri türü eğitim verisinde az sayıda olduğundan ve havuzlama katmanlarında veri kaybı meydana geldiğinden düşüş yaşandığı düşünülmektedir. Ek olarak, eğitim veri seti çeşitliliğinin artırılması bu duruma çözüm olabileceği öngörülmektedir.

Önceden eğitilmiş modelde mavi – kırmızı – yakın kızılötesi bant kombinasyonu ile eğitim işlemi gerçekleştirilmiştir. Sunulan tezde, aktarımlı öğrenmede kullanılan veri setini oluşturmak ve önceden eğitilmiş model ile uyumlu olması amacıyla mavi- kırmızı- yakın kızılötesi bantları seçilmiştir.

Sunulan çalışmada, aktarımlı öğrenmenin kıyı çizgisi çıkarımındaki performansı test edilmiştir. Benzer iki görev arasında bilgi aktarımı yapıldığından her iki görev için de ayrı ayrı büyük veri setleri hazırlamanın önüne geçilmiştir. Böylece zaman ve insan gücünden tasarruf edilmiştir.

Bu çalışmada, doğruluk analizi sonuçları aktarımlı öğrenme kullanarak SENTINEL-2 uydu görüntülerinden kıyı çizgisi çıkarımında verimli sonuçlar üretilebildiği sonucuna ulaşılmıştır. Elde edilen sonuçların kıyı yönetimi, katı madde taşınımı, kıyı çizgisi zamansal değişimi vb. çalışmalarda kullanılabilmesi düşünülmektedir.

- [1] Y. Zhang, X. Li, J. Zhang, ve D. Song, "A study on coastline extraction and its trend based on remote sensing image data mining," *Abstract and Applied Analysis*, vol. 2013.
- [2] R. Gens, "Remote sensing of coastlines: detection, extraction and monitoring," *International Journal of Remote Sensing*, 31(7), 1819–1836, 2010.
- [3] T. İşıaık Çolak, & G. Şenel ve Ç. Göksel, "Coastline zone extraction using Landsat-8 OLI imagery, case study: Bodrum Peninsula, Turkey," *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2019.
- [4] S. A. Salleh, N. S. Hasshim ve N. A. Adnan, "Comparative studies of remotely sensed coastline mapping techniques," *Built Environment Journal (BEJ)*, 12 (1). pp. 18-25. ISSN 1675-5022, 2015.
- [5] B. Pham ve I. Prakash, "Application of simple remote sensing techniques for the detection and extraction of coastline-A case study of Diu Island, India," *Indian Journal of Ecology*, 45. 778-784, 2018.
- [6] H. Hafizi ve K. Kalkan, "Evaluation of object-based water body extraction approaches using Landsat-8 imagery," 2020.
- [7] D. J. Lary, A. H. Alavi, A. H. Gandomi, ve A. L. Walker, "Machine learning in geosciences and remote sensing", *Geoscience Frontiers*, 7(1): 3-10, 2016.
- [8] L. Kumar, M. S. Afzal ve M.M. Afzal, "Mapping shoreline change using machine learning: A case study from the eastern Indian coast," *Acta Geophys*, 68, 1127–1143, 2020.
- [9] B. Bayram, F. Erdem, B. Akpınar, A. İnce, S. Bozkurt, H. Çatal, ve D. Şeker, "The efficiency of random forest method for shoreline extraction from Landsat-8 and Göktürk imageries," 2017.
- [10] J. Patterson ve A. Gibson, "Deep Learning: A Practitioner's Approach, First Edition", O'Reilly Media, California, 2017.
- [11] M. Wieland, S. Martinis ve Y. Li, "Semantic segmentation of water bodies in multi-spectral satellite images for situational awareness in emergency response". *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2019.
- [12] V. Syrris, P. Hasenohr, B. Delipetrov, A. Kotsev, P. Kempeneers ve P. Soille, "Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of SENTINEL-2 Imagery," *Remote Sensing*. 11. 907. 10.3390/rs11080907, 2019.
- [13] X. Liu, R. Jia, Q. Liu, C. Zhao ve H. Sun, "Coastline extraction method based on convolutional neural networks—A case study of Jiaozhou Bay in Qingdao, China," in *IEEE Access*, vol. 7, pp. 180281-180291, 2019.

- [14] L. Yang, S. Tian, L. Yu, F. Ye, J. Qian ve Y. Qian, "Deep learning for extracting water body from Landsat imagery," *International Journal of Innovative Computing, Information and Control*, 11(6), 1913-1929, 2015.
- [15] F. Erdem, B. Bayram, T. Bakirman, O. C. Bayrak ve B. Akpınar, "An ensemble deep learning based shoreline segmentation approach (WaterNet) from Landsat 8 OLI images," *Advances in Space Research*, 2020.
- [16] L. Torrey ve J. Shavlik, "Transfer Learning," University of Wisconsin, 2009.
- [17] A. Nazerdeylami, A. Majidi, Ve A. Movaghar, "Smart coastline environment management using deep detection of Manmade Pollution and Hazards," 5th Conference on Knowledge Based Engineering and Innovation (KBEI), pp. 332-337, 2019.
- [18] L. Moore, "Shoreline mapping techniques," *Journal of Coastal Research*, 16(1),111-124, 2000.
- [19] T. W. S. Warnasuriya, K. Gunaalan ve S. S. Gunasekara, "Google Earth: A new resource for shoreline change estimation—Case study from Jaffna Peninsula, Sri Lanka," 2018.
- [20] F. A.Sesli, "Sayısal Fotogrametri ile Kıyı Alanlarındaki Değişimin İzlenmesi," 2006.
- [21] B. Flemming ve J. Hansom, "Estuarine Coastal Geology and Geomorphology – A Synthesis," 10.1016/B978-0-12-374711-2.00301-6, 2011.
- [22] E. R. Thieler, T. L. Smith, J. M. Knisel, ve D. W. Sampson, "Massachusetts Shoreline Change Mapping and Analysis Project," 2013.
- [23] T. Fuse ve T. Ohkura, "Development of Shoreline Extraction Method Based on Spatial Pattern Analysis of Satellite SAR Images," *Remote Sens.* 2018, 10(9), 1361, 2018.
- [24] M. Louati, H Saïdi, ve F. Zargouni, "Shoreline change assessment using remote sensing and GIS techniques: a case study of the Medjerda delta coast, Tunisia," *Arab J Geosci* 8, 4239–4255, 2015.
- [25] R., Krishnamurthy, B.C. Glavovic, A. Kannu, D.R. Green, A. Ramanthau, Z. Han, S. Tinti ve T.S. Agardy, "Integrated Coastal Zone Management: The Global Challenge," Research Publications Services, Singapore, 780 pp, 2008.
- [26] "Remote Sensing Definition," <https://www.omnisci.com/technical-glossary/remote-sensing/>, 27.12.2020.
- [27] Geosci, Arab & Louati, Mourad & Saïdi, Hanen & Zargouni, Fouad. "Shoreline change assessment using remote sensing and GIS techniques: a case study of the Medjerda delta coast, Tunisia," 2014.
- [28] I. Goodfellow, Y. Bengio ve A. Courville, "Deep Learning, " MIT Press, Cambridge, 2016.

- [29] F. Günay, "Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme nedir ?," <https://faikgunay.com.tr/post/derin-ogrenme-nedir/>, 27.12.2020.
- [30] A. Şeker, "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme," Yıldız Teknik Üniversitesi, 2017.
- [31] H. Lee, R. Grosse, R. Ranganath ve A. Y. Ng, "Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations," Proceedings of the 26th annual international conference on machine learning, 2009.
- [32] F. Doğan, İ. Türkoğlu, "Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme," 2018.
- [33] M.İ. Ecevit, "A theoretical comparison of Resnet and Densenet architectures on the subject of shoreline extraction," Yüksek Lisans Tezi, Işık Üniversitesi, 2016.
- [34] A. Krizhevsky, I. Sutskever ve E. G. Hinton, "Imagenet classification with deep convolutional neural networks," In Advances in neural information processing systems, pp. 1097-1105, 2012.
- [35] "Sinir Ağları ve Derin Öğrenme — XIV : Aktivasyon Fonksiyonları," <https://medium.com/smlr-center/sinir-aglari-ve-derin-ogrenme-xiv-aktivasyon-fonksiyonlari-c125885ee5f7>, 27.12.2020.
- [36] Ö. İnik ve E. Ülker, "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, c. 6, sayı. 3, ss. 85-104, 2017.
- [37] Y. Tang, "Deep learning using linear support vector machines," 2013.
- [38] "Fully connected layers in convolutional neural networks: The complete guide - missinglink.ai," <https://missinglink.ai/guides/convolutional-neural-networks/fully-connected-layers-convolutional-neural-networks-complete-guide/>, 27.12.2020.
- [39] N. Çarkacı, "Derin öğrenme uygulamalarında en sık kullanılan hiperparametreler," <https://medium.com/deep-learningturkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiperparametreler-ece8e9125c4>, 2019.
- [40] D. Kriesel, "A brief introduction on neural networks," 2007.
- [41] Y. Bengio, "Practical recommendations for gradient-based training of deep architectures," In Neural networks: Tricks of the trade, pp. 437-478, 2012.
- [42] "Regularization," <https://ml-cheatsheet.readthedocs.io/en/latest/regularization.html/>, 27.12.2020.
- [43] N. Srivastava, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, 15: 1929–1958, 2014.

- [44] A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, V. ve J. GarciaRodriguez, "A review on deep learning techniques applied to semantic segmentation," Computing Research Repository (CoRR), abs/1704.06857, 2017.
- [45] F. Erdem, "LANDSAT-8 uydu görüntülerinden derin öğrenme algoritmaları kullanarak kıyı çizgisi," Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, 2018.
- [46] O. Ronneberger, P. Fischer ve T. Brox, "U-net: Convolutional networks for biomedical image segmentation," In International Conference on Medical image computing and computerassisted intervention, pp. 234-241, 2015.
- [47] S. J. Pan ve Q. Yang, "A Survey on Transfer Learning," in IEEE Transactions on Knowledge and Data Engineering, vol. 22, no. 10, pp. 1345-1359, 2010.
- [48] "TensorFlow Model Optimization Toolkit — Pruning API," <https://medium.com/tensorflow/tensorflow-model-optimization-toolkit-pruning-api-42cac9157a6a>, 27.12.2020.
- [49] E. R. Thieler, E. A. Himmelstoss, J. L. Zichichi ve A. Ergul, "The digital shoreline analysis system (DSAS) version 4.0-an ArcGIS extension for calculating shoreline change," 2009.
- [50] T. Zhang, X. Yang, S. Hu ve F. Su, "Extraction of coastline in aquaculture coast from multispectral remote sensing images: Object-based region growing integrating edge detection," Remote Sensing, 5(9): 4470-4487, 2013.
- [51] "USGS EROS Archive - Sentinel-2," [https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2?qt-science\\_center\\_objects=0#qt-science\\_center\\_objects](https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2?qt-science_center_objects=0#qt-science_center_objects) ], 27.12.2020.

# Tezden Üretilmiş Yayınlar

---

**İletişim Bilgisi:** selennurkaragol@gmail.com

## Ulusal Makale

1. S. Karagöl, B. Bayram, F. Erdem, ve T. Bakirman, “Aktarımlı Öğrenme ile SENTINEL-2 Görüntülerinden Kıyı Çizgisi Bölütlemesi,” Türkiye Uzaktan Algılama Dergisi, 2021.

