

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

**LANDSAT-8 UYDU GÖRÜNTÜLERİNDEN DERİN ÖĞRENME
ALGORİTMALARI KULLANARAK KIYI ÇİZGİSİ ÇIKARIMI**

FIRAT ERDEM

**YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
UZAKTAN ALGILAMA VE CBS PROGRAMI**

**DANIŞMAN
PROF. DR. BÜLENT BAYRAM**

İSTANBUL, 2018

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

LANDSAT-8 UYDU GÖRÜNTÜLERİNDEN DERİN ÖĞRENME
ALGORİTMALARI KULLANARAK KIYI ÇİZGİSİ ÇIKARIMI

Fırat ERDEM tarafından hazırlanan tez çalışması 21/06/2018 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Bülent BAYRAM

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Bülent BAYRAM


Yıldız Teknik Üniversitesi

Prof. Dr. Dursun Zafer ŞEKER

İstanbul Teknik Üniversitesi

Doç. Dr. Mustafa Ümit GÜMÜŞAY

Yıldız Teknik Üniversitesi





Sunulan tez çalışması, Prof. Dr. Bülent Bayram' ın yürütücülüğünü yaptığı 115Y718 numaralı ve "SÜRDÜRÜLEBİLİR KIYI ALANI İZLEME MODELİ İÇİN İHA VE İHA-LİDAR VERİLERİNDEN OTOMATİK ÜÇ BOYUTLU KIYI ÇİZGİSİ ÇIKARTILMASI VE ANALİZİ: TERKOS (İSTANBUL) ÖRNEĞİ" başlıklı TÜBİTAK 1001 projesi ile desteklenmiştir.

ÖNSÖZ

Değerli görüş ve önerileri ile çalışmama katkıda bulunan tez danışmanım Prof. Dr. Bülent Bayram'a,

Çalışmam boyunca zaman zaman fikirlerini ve tavsiyelerini aldığım çalışma arkadaşlarım Harita Mühendisi Onur Can Bayrak, Harita Yüksek Mühendisi Abdulkadir İnce ve Harita Yüksek Mühendisi Salih Bozkurt'a,

Eğitim hayatımın çeşitli periyotlarında teşvik ve önerileri ile destek aldığım çocukluk arkadaşım İnşaat Yüksek Mühendisi Murat Batuhan Koçak'a,

Maddi ve manevi desteklerini hiçbir zaman esirgemeyen, attığım adımlarda desteklerini her zaman kalbimde hissettiğim ve bana yol gösteren sevgili ailem; Sevcihan Dicle Erdem, Tülin Erdem, Kayserşah Erdem ve Ali Necati Bankoğlu'na,

Eğitim hayatım boyunca beni hiçbir zaman yalnız bırakmayan ve bana her zaman destek olan, hedeflerimi gerçekleştirmemde büyük bir pay sahibi olan Saliha Genç'e sonsuz teşekkürlerimi sunarım.

Mayıs, 2018

Fırat ERDEM

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ.....	xi
ÖZET.....	xii
ABSTRACT.....	xiv
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	5
1.3 Hipotez.....	6
BÖLÜM 2	
GENEL BİLGİLER.....	7
2.1 Kıyı Çizgisiyle İlgili Tanımlamalar.....	7
2.2 Kıyı Çizgisinin İzlenmesinin Önemi.....	8
2.3 Uzaktan Algılama ile Kıyı Çizgisi Çıkarımı.....	10
BÖLÜM 3	
YÖNTEM.....	12
3.1 Derin Öğrenme.....	12
3.1.1 Konvolüsyonel Sinir Ağları.....	13

3.1.1.1	Konvolüsyonel Sinir Ağları Mimarisi	14
3.1.1.1.1	Konvolüsyon Katmanları	15
3.1.1.1.2	Aktivasyon Fonksiyonları	16
3.1.1.1.3	Havuzlama Katmanları	17
3.1.1.1.4	Tam Bağlı Katman ve Softmax Katmanı	18
3.1.1.1.5	Düzenleştirme (Regularization)	19
3.1.2	Konvolüsyonel Sinir Ağları'nda Eğitim Parametreleri	20
3.1.2.1	Öğrenme Oranı	21
3.1.2.2	Mini-Batch Boyutu	21
3.1.2.3	Başlangıç Ağırlıkları	21
3.2	Konvolüsyonel Sinir Ağları ile Semantik Bölütleme	21
3.2.1	SegNet Mimarisi	23
3.3	Sayısal Kıyı Çizgisi Analizi Sistemi (Digital Shoreline Analysis System – DSAS) ...	25
BÖLÜM 4		
UYGULAMA		27
4.1	Kullanılan Donanım ve Yazılım	27
4.2	Materyal	27
4.3	Eğitim Veri Setinin Hazırlanması	30
4.4	SegNet Ağının Eğitimi	34
4.5	Kıyı Çizgilerinin Elde Edilmesi	37
4.6	Doğruluk Analizi	46
BÖLÜM 5		
SONUÇ VE ÖNERİLER		51
KAYNAKLAR		53
ÖZGEÇMİŞ		58

SİMGE LİSTESİ

w	Ağırlık matrisi
λ	Düzenleştirme büyüklüğü
$L_\lambda(w)$	Düzenleştirme penaltısı
X_i	i . kesit için kırı çizgileri arasında kalan dik mesafe
w_c	c sınıfının ağırlığı
f_c	c sınıfının frekansı
f_{median}	Sınıf frekanslarının medyanı

KISALTMA LİSTESİ

CNN	Convolutional Neural Network
DSAS	Digital Shoreline Analysis System
GPU	Graphics Processing Unit
KOH	Karesel Ortalama Hata
NDWI	Normalized Difference Water Index
NIR	Kızıl Ötesi Bant
OH	Ortalama Hata
RED	Kırmızı Bant
ReLU	Rectified Linear Unit
SGD	Stochastic Gradient Descent

ŞEKİL LİSTESİ

	Sayfa
Şekil 2. 1 Kıyı Kanunu'nda Yapılan Tanımlamalar [25]	8
Şekil 2. 2 Kıyı çizgisinin yıllara göre değişimi [26]	9
Şekil 2. 3 Uzaktan algılamada kullanılan platformlar ve algılayıcılar [35].....	11
Şekil 3. 1 Geleneksel makine öğrenmesi ve derin öğrenme algoritmalarında özellik çıkarımı [41]	13
Şekil 3. 2 Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki [40]	13
Şekil 3. 3 Düşük, orta ve yüksek düzey özellikler [42].....	14
Şekil 3. 4 Genel Konvolüsyonel Sinir Ağları mimarisi	15
Şekil 3. 5 Konvolüsyon İşlemi [43].....	16
Şekil 3. 6 Aktivasyon fonksiyonları	17
Şekil 3. 7 Maksimum havuzlama işlemi [45]	17
Şekil 3. 8 Tam Bağlı Katman	18
Şekil 3. 9 Dropout yöntemi [48]	20
Şekil 3.10 Derin öğrenme mimarilerinin görüntü analizinde kullanım alanları [53].....	22
Şekil 3.11 VGG16 mimarisi [55]	24
Şekil 3.12 SegNet mimarisinde üst örneklem oluşturma yöntemi [56].....	24
Şekil 3.13 SegNet mimarisi [54]	25
Şekil 3. 9 DSAS yapısı.....	26
Şekil 4. 1 Eğitim için kullanılan görüntülerin konumları	29
Şekil 4. 2 Test için kullanılan görüntülerin konumları	30
Şekil 4. 2 Eğitim verisi oluşturmak için kullanılan 2000 x 2000 boyutlarında bir görüntü örneği.....	31
Şekil 4. 3 Su ve kara sınıflarını ifade eden ikili görüntü örneği	32
Şekil 4. 4 Gürültü temizleme işlemi yapılmış ikili görüntü örneği.....	32
Şekil 4. 5 250 x 250 boyutlarında eğitim verisi elde etme işlemi.....	33
Şekil 4. 6 Eğitim veri setinden örnekler.....	34
Şekil 4. 7 Eğitim setinde bulunan piksellerin frekansları	35
Şekil 4. 8 SegNet VGG19 öğrenme grafiği	36
Şekil 4. 9 SegNet VGG16 öğrenme grafiği.....	37
Şekil 4.10 Test görüntüsünün 250 x 250 boyutlu parçalara bölünmesi ile elde edilen ikili görüntü	38
Şekil 4.11 SegNet ağıının test edilmesinde kullanılan yöntem	38
Şekil 4.12 Birinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü	39

Şekil 4.13	İkinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü .	39
Şekil 4.14	Üçüncü test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü	40
Şekil 4.15	Dördüncü test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü	40
Şekil 4.16	Beşinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü	41
Şekil 4.17	Birinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü	41
Şekil 4.18	İkinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü .	42
Şekil 4.19	Üçüncü test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü	42
Şekil 4.20	Dördüncü test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü	43
Şekil 4.21	Beşinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü	43
Şekil 4.22	Birinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)	44
Şekil 4.23	İkinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)	44
Şekil 4.24	Üçüncü test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)	45
Şekil 4.25	Dördüncü test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16).....	45
Şekil 4.26	Beşinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)	46
Şekil 4.27	DSAS elemanları. Kahverengi: kesitler, siyah: ana hat, kırmızı: elle sayısallaştırılan kıyı çizgisi, mavi: SegNet mimarisi ile elde edilen kıyı çizgisi	47

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 4. 1 LANDSAT–8 görüntülerinin teknik özellikleri [59]	28
Çizelge 4. 2 Kullanılan eğitim parametreleri	36
Çizelge 4. 3 SegNet VGG19 ağı için ortalama ve karesel ortalama hata değerleri.	47
Çizelge 4. 4 SegNet VGG16 ağı için ortalama ve karesel ortalama hata değerleri.	48
Çizelge 4. 5 SegNet VGG19 ağı için ayrıntılı doğruluk analizi.....	49
Çizelge 4. 6 SegNet VGG16 ağı için ayrıntılı doğruluk analizi.....	50

LANDSAT-8 UYDU GÖRÜNTÜLERİNDEN DERİN ÖĞRENME ALGORİTMALARI KULLANARAK KIYI ÇİZGİSİ ÇIKARIMI

Fırat ERDEM

Harita Mühendisliği Fotogrametri Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Bülent BAYRAM

Kıyı çizgileri; küresel ısınma gibi doğal etkiler, şehirleşmenin getirdiği nüfus artışı ve insan kaynaklı oluşan çevre kirliliği etkilerinden dolayı sürekli değişim halindedir. Bu değişimin zamansal olarak izlenmesi; kıyı kaynaklarının yönetimi, kıyı alanlarındaki çevrenin korunması ve sürdürülebilir kıyı planlaması için kritik bir öneme sahiptir. Optik uydu görüntülerinin kullanılmasıyla kıyı alanlarına ait güncel, doğru, zamansal ve güvenilir bilgiler elde edilebilmektedir. Makine öğrenmesi tabanlı Derin Öğrenme algoritmaları uydu görüntülerinden otomatik kıyı çizgisi çıkarımında kullanılabilmektedir. Sunulan tezde, LANDSAT-8 uydu görüntülerinden kıyı çizgisi çıkarımı için bir semantik bölütleme algoritması olan SegNet derin öğrenme mimarisi kullanılmıştır. SegNet mimarisi; kodlayıcı, kod çözücü ve sınıflandırma katmanlarını içermektedir. Kodlayıcı katmanlarda üretilen düşük çözünürlüklü özellik haritalarının, kod çözücü katmanlarda girdi görüntü ile aynı çözünürlüğe eşlenmesi prensibi benimsenmiştir. Çalışmada, 34 LANDSAT-8 görüntüsünün mavi, kırmızı ve yakın kızılötesi bantları kullanılmıştır. Kullanılan görüntülerin 29 tanesi SegNet Derin Öğrenme Ağı'nın eğitimi için ve 5 tanesi sonuçların test edilmesi için kullanılmıştır. Eğitim veri seti için etiket oluşturmak amacıyla LANDSAT-8 görüntülerinin NDWI (Normalleştirilmiş Fark Su İndeksi - Normalized Difference Water Index) görüntüleri oluşturulmuştur. NDWI görüntülerine eşik değer uygulanarak ikili görüntüler oluşturulmuş ve etiketler belirlenmiştir. Bu işlemin ardından 4880 adet görüntü parçasından oluşan eğitim veri seti hazırlanmıştır. MATLAB platformunda VGG16 ve VGG19 mimarilerini temel alan iki farklı SegNet derin öğrenme ağı

oluřturulmuř ve hazırlanmıř olan eęitim seti ile eęitim iřlemi gerekleřtirilmiřtir. SegNet derin ęrenme aęları kullanılarak, 5 adet test grntsnden su ve kara sınıfları ikili biimde elde edilmiřtir. İkili grntler vektr formata dnřtrlerek kıyı izgileri elde edilmiřtir. Kıyı izgilerinin doęruluklarını analiz etmek iin elle sayısallařtırılan kıyı izgileri kullanılmıřtır. Doęruluk analizi iin elle sayısallařtırılan kıyı izgileri referans veri olarak kullanılmıřtır.

alıřmanın sonucunda her bir test grntsnde SegNet-VGG19 mimarisi iin sırasıyla 13.38 m (0.45 piksel), 16.16 m (0.54 piksel), 20.32 m (0.68 piksel), 9.99 m (0.33 piksel) ve 12.63 m (0.42 piksel) ortalama hata hesaplanmıřtır. SegNet-VGG16 aęı iin ortalama hatalar sırasıyla 9.78 m (0.33 piksel), 25.67 m (0.86 piksel), 17.07 m (0.57 piksel), 11.11 m (0.37 piksel) ve 10.69 m (0.36 piksel) olarak hesaplanmıřtır. Elde edilen sonular, derin ęrenmenin ve SegNet semantik bltleme mimarisinin kıyı izgisi ıkarımında verimli bir řekilde kullanılabileceęini gstermektedir.

Anahtar Kelimeler: Derin ęrenme, grnt iřleme, uzaktan algılama, kıyı izgisi ıkarımı, LANDSAT-8.

**SHORELINE EXTRACTION FROM LANDSAT-8 SATELLITE IMAGERY BY
USING DEEP LEARNING ALGORITHMS**

Firat ERDEM

Department of Photogrammetry of Geomatics Engineering

MSc. Thesis

Adviser: Prof. Dr. Bülent BAYRAM

Shorelines are under rapid change due to natural influences such as global warming, population increase of urbanization and environmental pollution. Temporal monitoring of coastal change has a critical importance for coastal resource management, protection of coastal areas and sustainable coastal planning. By using optical satellite images, current, accurate, temporal and reliable information about coastal areas can be obtained. Machine learning based Deep Learning algorithms can be used to extract shoreline from satellite images that enable automatic shoreline extraction. In this thesis, SegNet deep learning architecture, which is a semantic segmentation algorithm is used for shoreline extraction from LANDSAT-8 satellite imagery. SegNet architecture consists of encoder layers, decoder layers and a classification layer. The principle is that the low-resolution feature maps generated in the encoder layers match to the same resolution as the input image in the decoder layers. In the study, blue, red and near infrared bands of 34 LANDSAT-8 images have been used. 29 of them have been used to obtain training SegNet Deep Learning Network and 5 of them for testing for the results. NDWI (Normalized Difference Water Index) of LANDSAT-8 images were created to generate labels for training data set. After applying the threshold value to the NDWI images, binary images have been created and the labels have been set. 4880 data sets were prepared. Two different SegNet deep learning networks based on the VGG16 and VGG19 architectures were created in the MATLAB platform and the training process was

carried out using prepared training set. Using SegNet Deep Learning Networks, Land and Water classes have been obtained in binary form from 5 test images. Binary images were converted into vector format and shorelines were obtained. Manual digitized shorelines were used as reference data for accuracy assessment.

As a result of study, for each test data, the calculated average errors were 13.38 m (0.45 pixel), 16.16 m (0.54 pixel), 20.32 m (0.68 pixel), 9.99 m (0.33 pixel) and 12.63 m (0.42 pixel) for SegNet-VGG19 network respectively. The average errors for SegNet- VGG16 network were 9.78 m (0.33 pixels), 25.67 m (0.86 pixels), 17.07 m (0.57 pixels), 11.11 m (0.37 pixels) and 10.69 m (0.36 pixels) respectively. The results show that deep learning and SegNet semantic segmentation architecture can be used efficiently for shoreline extraction.

Keywords: Deep learning, image processing, remote sensing, shoreline extraction, LANDSAT-8.

1.1 Literatür Özeti

Uydu görüntülerinden kıyı çizgisi çıkarımı, uzaktan algılama alanında önemli bir araştırma konusu olmuştur. Kıyı çizgisi çıkarımında uzaktan algılama teknolojilerinin kullanımıyla kısa sürede güvenilir bilgiler elde edilebilmektedir.

Yapılan çalışmalar incelendiğinde kontrollü ve kontrolsüz sınıflandırma yöntemlerinin kıyı çıkarımında kullanılabildiği görülmektedir. Maglione vd., yapmış oldukları çalışmada keskinleştirilmiş Worldview-2 görüntülerinin NDVI (Normalleştirilmiş Fark Bitki İndeksi - Normalized Difference Vegetation Index) ve NDWI (Normalleştirilmiş Fark Su İndeksi - Normalized Difference Water Index) görüntülerini oluşturmuşlardır. Ürettikleri indeks görüntülerine Maximum Likelihood (En Çok Benzerlik) kontrollü sınıflandırma yöntemini uygulayarak kıyı çizgisi elde etmişlerdir. Elle sayısallaştırılan kıyı çizgileri ile elde ettikleri kıyı çizgileri arasında kalan alanları kullanarak doğruluk analizi yapmışlardır. Çalışmanın sonuçlarına bakıldığında NDWI görüntülerinin, NDVI görüntülerine göre daha iyi sonuçlar verdiği görülmektedir [1].

Bir diğer çalışmada Sekovski vd., Iterative Self-Organizing Data Analysis Technique (ISODATA) kontrolsüz sınıflandırma yöntemi ile Parallelepiped, Gaussian Maximum Likelihood, Minimum-Distance-to-Means ve Mahalanobis Mesafesi (Mahalanobis Distance) kontrollü sınıflandırma yöntemlerinin kıyı çizgisi çıkarımındaki performansını araştırmıştır. Çalışmada Worldview-2 uydu görüntüleri kullanılmıştır. Yöntemlerin doğruluğunu analiz etmek için elle sayısallaştırılan kıyı çizgileri referans alınmıştır. ArcGIS yazılımının Yakınlık Analizi (Near Analysis) modülü kullanılarak yapılan doğruluk analizi

sonucunda Mahalanobis Mesafesi' nin en yüksek doğruluk değerini veren yöntem olduğu belirtilmiştir [2].

Uydu görüntülerinden kıyı çizgisi çıkarımında nesne tabanlı teknikler de literatürde yer edinmiştir. Bayram vd. tarafından gerçekleştirilen çalışmada farklı yıllara ait LANDSAT uydu görüntülerinden, Bayram vd. [4] tarafından geliştirilen Fit-Coast algoritması kullanılarak otomatik kıyı çizgisi çıkartılmıştır. Fit-Coast algoritması otomatik kıyı çizgisi çıkarımı için geliştirilmiş Alan Büyütme (Region Growing) tabanlı hibrit bir yöntemdir. Yöntemin doğruluğu elle sayısallaştırılan kıyı çizgisi referans alınarak araştırılmıştır. Doğruluk analizi sonuçlarına bakıldığında yöntemin kullanılabilir sonuçlar verdiği görülmektedir. Çalışmada, farklı yıllara ait görüntülerden üretilmiş kıyı çizgileri kullanılarak değişim analizi yapılmıştır. Ayrıca arazi kullanımı ve arazi örtüsü değişiminin kıyı çizgisi değişimine olan etkisi, obje temelli sınıflandırma yöntemi kullanılarak araştırılmıştır [3].

Bir diğer çalışmada Zhang vd., otomatik kıyı çizgisi çıkarımı için kenar yakalama ve Alan Büyütme entegrasyonunu kullanan bir yöntem önermişlerdir. Yöntemi LANDSAT-5 ve SPOT-5 görüntüleri üzerinde uygulayarak kıyı çizgisi çıkartmışlardır. Doğruluk analizi için çıkartılan kıyı çizgileri, elle sayısallaştırılan kıyı çizgileri ile karşılaştırılmıştır. Bu işlem için United States Geological Survey (USGS) tarafından geliştirilen ve bir ArcGIS eklentisi olan Sayısal Kıyı Çizgisi Analiz Sistemi (Digital Shoreline Analysis System - DSAS) kullanılmıştır. Doğruluk analizi sonuçları incelendiğinde yöntemin 1 piksel doğruluğunun altında sonuçlar verdiği gözlemlenmektedir [5].

Rishikeshan ve Ramesh, yapmış oldukları çalışmada uydu görüntülerinden kıyı çizgisi çıkarımı için matematiksel morfolojiyi kullanan yarı otomatik bir yaklaşım ileri sürmüşlerdir. Geliştirdikleri yöntemi Cartosat-2, Cartosat-1, Resourcesat-2 ve LANDSAT-8 görüntüleri kullanarak test etmişlerdir. Yöntemin doğruluğunu analiz etmek için elle sayısallaştırılan kıyı çizgilerini kullanmışlardır. Doğruluk analizi sonuçlarına bakıldığında geliştirilen yöntemin hem düşük hem de yüksek çözünürlüklü görüntülerde yüksek doğruluk değeri verdiği gözlemlenmektedir [6].

Son yıllarda uzaktan algılama uygulamalarında, uydu görüntülerinden obje çıkarımı ve uydu görüntülerinin sınıflandırılması konularında makine öğrenmesi teknikleri

kullanılmıştır [7]. Choung ve Jo, yapmış oldukları çalışmada Worldview-2 uydu görüntülerini kullanarak bir makine öğrenmesi yöntemi olan Destek Vektör Makineleri (Support Vector Machines) ile NDWI ve Adaptif Eşikleme (Adaptive Thresholding) tabanlı yöntemin kıyı çizgisi çıkarımındaki performansını karşılaştırmıştır. Yöntemlerin doğruluklarını analiz etmek için elle sayısallaştırılan kıyı çizgileri kullanılmıştır. Çalışmanın sonuçlarına bakıldığında Destek Vektör Makinelerinin NDWI tabanlı yöntemle göre daha yüksek doğruluk değeri verdiği görülmektedir [8].

Goodfellow vd. derin öğrenmeyi, bilgisayarların insanlara benzer bir şekilde basit kavramların hiyerarşisinden yararlanarak öğrenmelerine dayanan bir makine öğrenmesi yöntemi olarak tanımlamışlardır [9]. Diğer makine öğrenmesi yöntemleri gibi derin öğrenme algoritmaları da son yıllarda uzaktan algılama literatüründe yer edinmiştir.

Längkvist vd., çalışmalarında 0,5 m konumsal çözünürlüğe sahip ortofotolar ile Sayısal Yüzey Modeli (SYM) kullanarak bitki örtüsü, toprak, yol, bina ve su sınıflarını içeren bir sınıflandırma işlemi gerçekleştirmişlerdir. Yaptıkları uygulamada Konvolüsyonel Sinir Ağları'nı (Convolution Neural Networks – CNN) kullanmışlardır. Sınıflandırma doğruluğunun artırılması işlemi için Yalın Doğrusal Yinelemeli Kümeleme (Simple Linear Iterative Clustering - SLIC) bölütleme algoritmasını kullanmışlardır. Sınıflandırma sonuçlarına bakıldığında %94,49'luk bir sınıflandırma doğruluğu gözlemlenmektedir. Ayrıca yapılan çalışmada SLIC algoritması sonucunda üretilen bölütlerin, Konvolüsyonel Sinir Ağları ile üretilen sınıflandırma sonuçları kullanılarak birleştirilmesi işlemi de gerçekleştirilmiştir [10].

Başka bir çalışmada Panboonyuen vd., hava fotoğrafları ve uydu görüntülerinden yolların otomatik bölütlenmesi için SegNet olarak adlandırılan derin konvolüsyonel kodlayıcı-kod çözücü ağ mimarisine, Exponential Linear Unit (ELU) aktivasyon fonksiyonu ile peysaj metrikleri (landscape metrics) ve Şartlı Rastgele Alanlar (Conditional Random Fields) yöntemini entegre ederek yeni bir yöntem önermişlerdir. Çalışmada iki veri seti kullanılmıştır. Birinci veri setinde 1171 adet 1500 x 1500 boyutlarında, 1 m konumsal çözünürlüğe sahip hava fotoğrafları bulunmaktadır. İkinci veri setinde ise 855 adet 1500 x 1500 boyutlarında, 2 m konumsal çözünürlüğe sahip THEOS (Thailand Earth Observation System) uydu görüntüleri bulunmaktadır. Yapılan doğruluk analizi

sonucunda önerilen yöntemin her iki veri seti için de standart SegNet mimarisine göre daha iyi sonuçlar verdiği gözlemlenmektedir [11].

Bir diğer çalışmada Audebert vd., kara araçlarının otomatik bölütlenmesi ve tespiti için SegNet derin öğrenme mimarisini kullanmışlardır. Çalışmalarında SegNet derin öğrenme ağının eğitimi ve test edilmesi için ISPRS Postdam semantik etiketleme veri setini [12] ve NZAM/ONERA Christchurch veri setinden [13] 4 görüntüyü kullanmışlardır. Postdam veri seti 5 cm konumsal çözünürlüğe sahip 6000 x 6000 boyutlarında 38 adet görüntüden oluşmaktadır. Christchurch veri seti ise 10 cm konumsal çözünürlüğe sahiptir ve yaklaşık 5000 x 4000 boyutlarındadır. Bölütlenen araçların türlerine göre sınıflandırılması işlemi için 1024 x 1024 boyutlarında, 12,5 cm konumsal çözünürlüğe sahip 1268 adet görüntüden oluşan Vedai veri setini [14] kullanmışlardır. Çalışmanın doğruluk analizi sonuçlarına bakıldığında SegNet mimarisi kullanarak otomatik araç bölütlemesinin ve tespitinin her iki veri seti için de başarılı sonuçlar verdiği gözlemlenmektedir. Ayrıca yapılan çalışmada tespit edilen araçların sayıları kullanılarak trafik yoğunluğu tahminleri de yapılmıştır [15].

Xu vd., yapmış oldukları otomatik bina çıkarımı için Res-U-Net derin öğrenme mimarisini kullanmışlardır. Çalışmalarında Postdam semantik etiketleme veri setine ek olarak ISPRS tarafından yayınlanan, 2500 x 2500 boyutlarında, 9 cm konumsal çözünürlüğe sahip 33 adet görüntüden oluşan Vaihingen veri setini kullanmışlardır. Yöntemlerinin doğruluğunu artırmak için NDVI görüntülerini ve görüntü eşleme ile üretilen Sayısal Yüzey Modeli (SYM) verilerini kullanmışlardır. Ayrıca görüntülerin ön işlenmesi aşamasında görüntü keskinleştirme operatörleri kullanmışlardır. Sonuç ikili görüntülerdeki gürültü efektlerinin giderilmesi için Guided Filter algoritmasını kullanmışlardır. Doğruluk analizi sonuçları incelendiğinde her iki veri seti için de %97 oranında bir doğruluk sonucu elde edilmiştir [16].

Isikdogan vd., çalışmalarında önerdikleri DeepWaterMap adında kodlayıcı – kod çözücü derin öğrenme ağı mimarisini temel alan bir Tam Konvolüsyonlu Ağ (Fully Convolutional Network) yapısı kullanarak uydu görüntülerinden su gövdesi çıkarımı gerçekleştirmişlerdir. Çalışmada LANDSAT-7 ETM+ uydu görüntülerinden oluşan GLS2000 veri setini [17] kullanmışlardır. Veri setlerinin etiketlenmesi için Feng vd.

tarafından üretilen; kara, su, kar/buz, gölge ve bulut sınıflarını içeren GLCF veri setini [18] kullanmışlardır. DeepWaterMap ile bulunan sonuçları, Çok Katmanlı Algılayıcı (Multilayer Perceptron - MLP) ve MNDWI (Modifiye Edilmiş Normalize Fark Su İndeksi - Modified Normalized Difference Water Index) görüntülerine eşik değeri uygulanması yöntemleri ile karşılaştırılmıştır. Doğruluk analizi sonuçları incelendiğinde DeepWaterMap'in %90 doğruluk ile MLP ve MNDWI yöntemlerinden daha doğru sonuçlar verdiği gözlemlenmektedir [19].

Yang vd., SSAE (Stacked Sparse Autoencoder) derin öğrenme mimarisini kullanarak LANDSAT görüntülerinden su gövdesi çıkarımı gerçekleştirmişlerdir. Çalışmada her pikselin NDWI, NDVI, NDBI (Normalize Fark Bina İndeksi - Normalized Difference Built Index) gibi özellik değeri belirlenerek doğruluğun artması hedeflenmiştir. Özellik genişleme algoritması (Feature Expansion Algorithm) kullanılarak piksel komşulukları dikkate alınmış, özellik matrisleri genişletilmiştir. Genişletilen özellik matrislerinin SSAE derin öğrenme ağına girdi olarak verilmesi önerilmiştir. Önerilen yöntem, geleneksel yapay sinir ağları ve DVM yöntemlerinden daha üstün performans göstermiştir [20].

1.2 Tezin Amacı

Kıyı çizgisinin tespiti ve kıyı alanlarının haritalarının oluşturulması; güvenli navigasyon, kıyı kaynaklarının yönetimi, kıyı alanlarındaki çevrenin korunması ve sürdürülebilir kıyı planlaması için kritik bir öneme sahiptir. Kıyı çizgisinde meydana gelen değişimler kıyı bölgesinin çevresini etkileyebilmektedir. Bu değişimler, doğal süreçlerden veya insan faaliyetlerinden kaynaklanabilmektedir [21]. Uydu görüntüleri kullanılarak kıyı çizgilerinin izlenmesiyle, yersel ölçümler ile elde edilemeyecek anlık ve zamansal verilerin elde edilmesi olanaklı olmaktadır [22].

Uydu görüntülerinden kıyı çizgisi çıkarımı ile ilgili yapılan çalışmalar incelendiğinde yarı-otomatik yaklaşımların yanı sıra makine öğrenmesine dayalı yaklaşımların kullanıldığı da görülmektedir. Sunulan tez çalışmasında son yıllarda popülerite kazanan ve makine öğrenmesinin bir dalı olan derin öğrenme yöntemlerinin kıyı çizgisi çıkarımındaki performansının incelenmesi amaçlanmıştır.

1.3 Hipotez

Sunulan tez çalışması; uzaktan algılama teknolojisinin kıyı çizgisi çıkarımındaki katkısının araştırılması, derin öğrenme yönteminin ve derin öğrenme yönteminde kullanılan kavramların incelenmesi ve “LANDSAT-8 uydu görüntülerinden derin öğrenme yöntemi kullanılarak yüksek konumsal doğrulukta kıyı çizgisi çıkarımı mümkün müdür?” hipotezi üzerine kurulmuştur.



2.1 Kıyı Çizgisiyle İlgili Tanımlamalar

Kıyı çizgisi, Dolan vd. tarafından “kara ve su arasındaki fiziksel ara yüzey” olarak tanımlanmaktadır [23].

Ülkemizde 17.04.1990 tarihinde yayımlanan ve yürürlükte olan 3621 Sayılı Kıyı Kanunu ve bu kanunun bazı maddelerinde değişiklik yapılmasına dair 3830 Sayılı Kıyı Kanuna’na göre kıyı çizgisi ile ilgili yapılan tanımlamalar şu şekildedir [24]:

“Kıyı çizgisi: Deniz, tabii ve suni göl ve akarsularda, taşkın durumları dışında, suyun karaya değdiği noktaların birleşmesinden oluşan çizgiyi,


Kıyı Kenar çizgisi: Deniz, tabii ve suni göl ve akarsularda, kıyı çizgisinden sonraki kara yönünde su hareketlerinin oluşturulduğu kumluk, çakıllık, kayalık, taşlık, sazlık, bataklık ve benzeri alanların doğal sınırını,

Kıyı: Kıyı çizgisi ile kıyı kenar çizgisi arasındaki alanı,

Sahil şeridi: Kıyı kenar çizgisinden itibaren kara yönünde yatay olarak en az 100 metre genişliğindeki alanı,

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


Şekil 2.1.’de Kıyı Kanunu’ndaki tanımlamalar gösterilmektedir.



Şekil 2.1 Kıyı Kanunu'nda Yapılan Tanımlamalar [25]

2.2 Kıyı Çizgisinin İzlenmesinin Önemi

Kıyı çizgisinin tespiti ve kıyı alanlarının haritalarının oluşturulması; güvenli navigasyon, kıyı kaynaklarının yönetimi, kıyı alanlarındaki çevrenin korunması ve sürdürülebilir kıyı planlaması için kritik bir öneme sahiptir. Kıyı çizgisinde meydana gelen değişimler kıyı bölgesinin çevresini etkileyebilmektedir. Bu değişimler, doğal süreçlerden veya insan faaliyetlerinden kaynaklanabilmektedir [21]. Şekil 2.2'de Atlantik Okyanusu'nda örnek bir alanda kıyı çizgisinin yıllara göre değişimi gösterilmiştir.



Şekil 2.2 Kıyı çizgisinin yıllara göre değişimi [26]

Kıyı alanları, en çok tehdit altında olan ekosistemlerden biridir. Nüfus artışı ve küresel ısınmanın sonucu olarak kirlilik, kentleşme ve şiddetli hava olaylarına bağlı olarak erozyonların artması, kıyı alanlarının yönetimini önemli kılmaktadır [27].

Sale vd. tarafından yapılan çalışmada, 2050 yılına gelindiğinde dünyadaki kıyı alanlarının %91'inin gelişiminin düzensiz planlama sebebiyle olumsuz etkileneceği öngörülmüştür [28].

Küresel ısınmanın en belirgin sonuçlarından biri, deniz seviyesindeki yükseliştir. Yükselen deniz seviyesinden kaynaklanan su baskını, düşük yükseklikteki bölgeleri büyük ölçüde etkileyecektir. Yaklaşık 100 milyon kişi ortalama deniz seviyesinin yaklaşık 1 metre dahilinde yaşamaktadır ve bu insanlar gelecek yıllarda daha fazla risk altında olacaktır. Bazı ada ülkeleri ve delta oluşturan kıyılar, deniz seviyesinin yükselmesiyle tehdit altındadır [29].

Kıyı alanları, turizm faaliyetleri ve estetik değ rlere ek olarak, ekonomik  nemi olan balık ılık faaliyetlerinin desteklenmesinde ve nitrojen gibi temel ya am kaynaklarının d ng s nde  nemli bir role sahiptir [30].

Sulak alanların ve tarımsal arazi kaynaklarının belirlenmesi, sel ve kasırga tehlikesi barındıran b lgelerin ve cephe hattından  nde in a edilen yapıların tespit edilmesi i in kıyı alanlarına ili kin topo rafik haritaların g ncel ve do ru bir  ekilde hazırlanmasına ihtiya  duyulmaktadır [31].


Uluslararası Co rafi Veri Komitesi (International Geographic Data Committee - IGDC), kıyı alanlarını yery z ndeki en  nemli 27 do al zenginlikten biri olarak g stermi tir [32].

2.3 Uzaktan Algılama ile Kıyı  izgisi  ıkarımı

Uzaktan algılama, ara tırma konusu olan nesne veya alan ile temas halinde olmayan bir cihaz tarafından elde edilen verilerin analizi yoluyla ilgili nesne veya alan ile ilgili bilgi edinme bilimi ve sanatıdır [33].

Bir ba ka tanımlamada uzaktan algılama, herhangi bir temas olmadan d nyanın y zeyi ile ilgili bilgileri elde etme bilimidir. Bu, yansıyan veya yayılan enerjinin algılanması, kaydedilmesi ve elde edilen bilgilerin i lenmesi ve analiz edilmesi ile ger ekle tirilir [34].

 ekil 2.3.'de uzaktan algılamada kullanılan platformlar ve algılayıcılar verilmi tir.



Şekil 2.3 Uzaktan algılamada kullanılan platformlar ve algılayıcılar [35]

Uzaktan algılamada obje çıkarımı (object extraction), görüntü bölgeleri arasındaki karşılıklı ilişkileri tanımlamak ve sınıflandırmak için kullanılan görüntü işleme teknikleri olarak tanımlanabilir [36]. Uydu görüntülerine çeşitli görüntü işleme teknikleri uygulanarak ilgilenilen nesnelerin otomatik olarak diğer nesnelerden ayrıştırılması sağlanabilmektedir [37].

Kıyı alanlarının izlenmesi ve kıyı çizgisi çıkarımına yönelik yapılan çalışmalarda yersel ölçüm, fotogrametrik yöntemler, uzaktan algılama verileri kullanılabilmektedir [38].


Uydu görüntüleri kullanılarak kıyı çizgilerinin izlenmesi, yersel ölçümler ile elde edilemeyecek anlık ve zamansal verilerin elde edilmesini olanaklı kılmaktadır [22].

Optik uydu görüntülerinin kullanılmasıyla kıyı alanlarına ait güncel, doğru, zamansal ve güvenilir bilgiler elde edilebilmektedir [39].


3.1 Derin Öğrenme

Goodfellow vd. derin öğrenmeyi, bilgisayarların insanlara benzer bir şekilde basit kavramların hiyerarşisinden yararlanarak öğrenmelerine dayanan bir makine öğrenmesi yöntemi olarak tanımlamışlardır [9].

Derin öğrenmenin geleneksel makine öğrenme algoritmalarına göre en büyük avantajı otomatik özellik çıkartma yeteneğinin olmasıdır [40]. Özellik çıkartma (feature extraction), kullanılan veri setinde hangi özelliklerin kullanılacağına karar verme sürecidir. Geleneksel makine öğrenme algoritmalarında bu süreç, uygulayıcının uzun bir süre veri setini analiz ederek uygun özellikleri seçmesi ile gerçekleşmektedir. Derin öğrenme algoritmalarında ise bu süreç otomatik bir şekilde gerçekleşmektedir (Şekil 3.1). Şekil 3.2.'de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki ifade edilmektedir.



Şekil 3.1 Geleneksel makine öğrenmesi ve derin öğrenme algoritmalarında özellik çıkarımı [41]



Şekil 3.2 Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki [40]


Günümüzde derin öğrenme; görüntü tanıma, görüntü bölütleme, ses tanıma ve doğal dil işleme gibi birçok farklı alanda kullanılmaktadır [9].

3.1.1 Konvolüsyonel Sinir Ağları

Sinir ağlarının özel bir türü olan Konvolüsyonel Ağlar veya bir diğer adıyla Konvolüsyonel Sinir Ağları (Convolutional Neural Networks – CNN), ızgara (grid) topolojisine benzer topolojiye sahip olan verileri işlemek için kullanılır. Izgara topolojisine sahip verilere örnek olarak, 1 boyutlu ızgara topolojisi şeklinde düşünülebilen zaman serisi verileri ve

piksellerin 2 boyutlu ızgara topolojisi ile ifade edildiği görüntü verileri gösterilebilir. Konvolüsyon Sinir Ağları, pratik uygulamalarda son derece başarılı olmuştur. “Konvolüsyonel Sinir Ağları” adı, ağın konvolüsyon adı verilen bir matematiksel işlemin kullandığını göstermektedir [9].


Konvolüsyonel Sinir Ağları’nın amacı, verilerdeki yüksek düzeyli özellikleri konvolüsyonlar yoluyla öğrenmektir. Özellikle görüntü tanıma problemlerinin çözümü için uygun bir yöntemdir. Şekil 3.3.’te düşük, orta ve yüksek düzey özellik çıkarımına ilişkin bir örnek gösterilmektedir [40].



Şekil 3.3 Düşük, orta ve yüksek düzey özellikler [42]

3.1.1.1 Konvolüsyonel Sinir Ağları Mimarisi


Konvolüsyonel Sinir Ağları, girdi katmanındaki verileri Tam Bağlı Katman’dan üretilen bir dizi sınıf puanına dönüştürür. Konvolüsyonel Sinir Ağları mimarilerinin birçok çeşidi bulunmaktadır. Ancak tüm yaklaşımlar Şekil 3.4.’de gösterilen ağ modelini temel almaktadır. Şekilde girdi katman ile ağ mimarisi ilişkisi verilmiştir. Girdi katmanı, görüntü metin bilgisi, farklı ölçülere ilişkin bilgiler gibi çok farklı verilerden oluşabilmektedir. Örneğin üç banttıan oluşan bir görüntüye ilişkin RGB (Kırmızı-Yeşil-Mavi) veri girdi verisi olarak kullanıldığında girdi katmanının derinliği 3’tür [40].



Şekil 3.4 Genel Konvolüsyonel Sinir Ağları mimarisi

3.1.1.1.1 Konvolüsyon Katmanları

Konvolüsyon işlemi, CNN'in özellik çıkartma işlemi olarak bilinmektedir. Konvolüsyon işleminin girdi verisi ham veri veya başka bir konvolüsyon işleminin çıktısı (özellik haritasının bir elemanı) olabilmektedir. Bu işlem, çekirdek matris kullanılarak girdi verilerinin belirli türdeki bilgileri çıkartmak için kullanıldığı bir filtreleme işlemi olarak yorumlanmaktadır. Örneğin, bir kenar yakalayıcı çekirdek matrisi, yalnızca bir görüntüdeki kenar içeren bilgileri iletmektedir [40]. Şekil 3.5.'te özellik haritasının üretilmesi için girdi verileri ile çekirdek matris kullanılarak konvolüsyon işlemine ilişkin örnek sunulmuştur.



Şekil 3.5 Konvolüsyon İşlemi [43]


Şekil 3.5.'ten görüldüğü gibi, girdi verisinde her piksel için, çekirdek matris sınırları içinde kalan pikseller çekirdek matris ile çarpılarak özellik haritası oluşturulur. Aranılan özelliğin girdi verisinde tespit edilmesi durumunda yeni gri değer, kaynak pikseldeki değerden daha büyük bir değer olur.

Konvolüsyon katmanındaki çekirdek matrisinin elemanları ağırlık olarak adlandırılmaktadır. Ağırlıkların belirlenmesi işlemi için Konvolüsyonel Sinir Ağları, eğitim veri seti kullanılarak Stochastic Gradient Descent (SGD) algoritması ile eğitilir.

3.1.1.1.2 Aktivasyon Fonksiyonları

Konvolüsyonel Sinir Ağlarında, konvolüsyon sonucunda üretilen özellik haritasındaki her bileşene aktivasyon fonksiyonu uygulanarak özellik haritasına doğrusal olamayan bir yapı kazandırılır.

En sık kullanılan aktivasyon fonksiyonları ReLU (Rectified Linear Unit), Sigmoid ve Hiperbolik Tanjant fonksiyonlarıdır. ReLU, Sigmoid ve Hiperbolik Tanjant fonksiyonlarının grafikleri ve eşitlikleri Şekil 3.6.'da gösterilmektedir. Yapılan çalışmalara bakıldığında ReLU fonksiyonunun daha doğru sonuçlar ürettiği görülmüştür. ReLU fonksiyonu, negatif girdileri sıfır olarak, pozitif girdileri ise değiştirmeden etkinleştirir [44]. ReLU katmanları, ek parametrelere sahip değildir [40].




Şekil 3.6 Aktivasyon fonksiyonları

3.1.1.1.3. Havuzlama Katmanları

Havuzlama katmanları (pooling layers), genellikle konvolüsyon katmanından üretilen verilerin örneklenmesi amacıyla kullanılır. Girdi verisinin boyutu, girdi verisi boyunca kaydırılan bir havuzlama penceresi kullanılarak azaltılır.

Bir havuzlama işleminde, konvolüsyon katmanından üretilen görüntü, üst üste gelmeyen alt alanlara ayrılır ve her alt alanın maksimum değeri alınır. Maksimum havuzlamaya alternatif olarak örneklemelerin ortalamasının alınmasını ifade eden ortalama havuzlama işlemi kullanılabilmektedir. Havuzlama katmanından elde edilecek verilerin boyutlarını kontrol etmek için kaydırma mesafesi (slide) ve pencere boyutu değiştirilebilmektedir [9]. Şekil 3.7’de maksimum havuzlama işlemi açıklanmaktadır.




Şekil 3.7 Maksimum havuzlama işlemi [45]

Havuzlama katmanı ile gereksiz bilgilerin kullanılması engellenerek hesaplama maliyeti azaltılır, böylece Konvolüsyonel Sinir Ağı daha verimli hale getirilir [9].

3.1.1.1.4. Tam Bağlı Katman ve Softmax Katmanı

Konvolüsyon ve havuzlama katmanlarında yüksek seviyeli özellikler tespit edildikten sonra, ağın sonunda genellikle Tam Bağlı Katman (Fully Connected Layer) bulunmaktadır. Bu katmandaki tüm nöronlar ile önceki katman arasında bağ bulunmaktadır. Tam Bağlı Katman, Konvolüsyonel Sinir Ağları sonucundan üretilecek olan sınıf puanlarını hesaplamak için kullanılmaktadır [40]. Şekil 3.8.'de Tam Bağlı Katman'ın yapısı gösterilmektedir.



Şekil 3.8 Tam Bağlı Katman

Tam Bağlı Katman'daki bir nöron bir önceki katmandaki tüm nöronları kullandığı için konumsal bilginin kaybolması söz konusu olabilmektedir. Bu, konumsal bilginin önemli olduğu semantik bölütleme problemleri için istenmeyen bir durumdur [46].

Tam bağlı katmanın ardından etiket tahmini işlemi için Softmax sınıflandırıcı katmanı kullanılır [47]. Görüntünün semantik içeriğine ilişkin tahmin işlemlerinde tam bağlı katman kullanılmasına karşın, bölütleme problemlerinde tam bağlı katman silinerek sunulan tez çalışmasında olduğu gibi etiketler belirlenerek piksel bazlı etiketleme yapılır.

Etiketlerin belirlenmesine yönelik en son olasılık tahmininin yapıldığı Softmax fonksiyonu girdi verisinin (x_i) belirli bir sınıfa (k) ait olma olasılığını hesaplamaktadır:

$$p(y = k | \bar{x} = x_i) = \frac{e^{(s_k)}}{\sum_j e^{(s_j)}} \quad (3.1)$$


Burada s , Konvolüsyonel Sinir Ağının önceki katmanlarından belirli bir sınıf için elde edilen sınıf puanıdır.

3.1.1.1.5. Düzenlileştirme (Regularization)

Aşırı öğrenme (overfitting), makine öğrenme algoritmalarının eğitim veri setini doğru öğrenememesi ve bunun sonucu olarak yanlış sınıflandırmaya neden olur. Dolayısı ile, derin öğrenme ağının büyük veri setlerinde kullanılması olanaksızlaşır. Eğer derin öğrenme modeli, fazla sayıda benzer niteliğe sahip eğitim verileri ile eğitilirse farklı nitelikteki test verilerinde düşük performans gösterir. Benzer şekilde eğer derin öğrenme modeli, eğitim verileri üzerinde çok fazla öğrenme gerçekleştirirse farklı test verileri için düşük performans gösterir. Aşırı öğrenmeyi engellemek için geliştirilen yöntemler, düzenlileştirme (regularization) yöntemleri olarak adlandırılmaktadır [40].

Dropout ve L2 yöntemleri en yaygın olarak kullanılan düzenlileştirme yöntemleridir. Bu yöntemlerden birisi olan Dropout yöntemi, ağın eğitimi aşamasında yer alan basit ve etkili bir düzenlileştirme yöntemidir. Bir olasılık değeri ile karakterize edilen Dropout katmanlarının ağa entegre edilmesi ile uygulanır. Bir eğitim adımındaki her nöron, yöntem ile hesaplanan olasılıklara göre işleme dahil edilir ya da edilmez. Böylelikle derin öğrenme ağı, iteratif olarak belirli nöronları aktif ederek veya etmeyerek örneklenir [48]. Şekil 3.9'da Dropout yöntemi açıklanmaktadır. Şekilde, sol tarafta standart bir sinir ağı,

sağ tarafta ise Dropout uygulandıktan sonra üretilen sinir ağı gösterilmektedir.



Şekil 3.9 Dropout yöntemi [48]

Dropout yöntemi, tam bağlı katmanlarda verimli olmasına karşın konvolüsyon katmanlarında daha verimsiz performans göstermektedir [49]. Bu nedenle konvolüsyon katmanlarının kullanıldığı görüntüden obje çıkartma uygulamalarında bir başka düzenleme yöntemi olan L2 düzenleme (L2 regularization) yöntemi kullanılmaktadır. Sunulan çalışmada L2 düzenleme yöntemi kullanılmıştır.

L2 düzenlemesi yönteminde, tüm ağırlık değerlerinin büyüklüklerinin karesi doğrudan kayıp fonksiyonuna eklenir ve toplam kayıp fonksiyonu minimize edilir. L2 düzenlemesi, genelleştirmeyi iyileştirir ve kullanılmayan ağırlıkların göz ardı edilmesine yardımcı olur [47]. Düzenleme penaltısı (3.2)'deki gibi hesaplanmaktadır. Burada w , ağırlık matrisini ve λ , düzenleme büyüklüğünü göstermektedir [50].

$$L_{\lambda}(w) = L(w) + \lambda \|w\|_2^2 \quad (3.2)$$

3.1.2 Konvolüsyonel Sinir Ağları'nda Eğitim Parametreleri

Eğitim parametreleri, kullanıcı tarafından seçilen ve sinir ağının performansını önemli ölçüde etkileyen değişkenlerdir. Eğitim parametreleri :Öğrenme Oranı, Mini-Batch Boyutu ve Başlangıç Ağırlıkların belirlenmesi olmak üzere üç alt gruba ayrılabilir.

3.1.2.1 Öğrenme Oranı

Makine öğrenmesinde öğrenme oranı (learning rate), ağ parametrelerinin ne kadar hızlı güncellendiğini göstermektedir. Eğer öğrenme oranı çok yüksek bir değer olarak seçilirse, ağı öğrenme süresi daha kısa bir sürede tamamlanabilmekte fakat optimum çözüme yakınsamayan, dengesiz eğitim sonuçları üretilebilmektedir. Eğer öğrenme oranı çok düşük bir değer seçilirse, ağı öğrenme süresi uzun olabilmektedir. Ayrıca düşük bir öğrenme oranı değerinin seçilmesi, öğrenme algoritmasını verimsiz hale getirebilmektedir. Öğrenme oranının değeri, veri kümesine ve diğer parametrelere bağlı olarak belirlenmektedir [40].

3.1.2.2 Mini-Batch Boyutu

Mini-Batch kullanılarak öğrenme sistemine eğitilmek üzere birden fazla giriş vektörü gönderilmektedir. Böylelikle, bilgisayar donanımının ve kaynaklarının daha efektif bir düzeyde kullanılması sağlanmaktadır. Bu yöntem aynı zamanda belirli lineer cebir işlemlerinin (özellikle matris çarpımlarının) vektörel bir şekilde hesaplanmasını sağlamaktadır. Ayrıca, kullanılan bilgisayar sisteminde grafik işlemci ünitesi (Graphics Processing Unit - GPU) bulunması durumunda vektörel hesaplamaların grafik işlemci ünitesinde hesaplanması sağlanabilmektedir [51].


3.1.2.3 Başlangıç Ağırlıkları

Başlangıç ağırlıklarının nasıl belirleneceği işlemi, eğitim sürecini büyük ölçüde etkileyebilmektedir. Bias değerleri genellikle sıfır olarak başlatılabilmekte iken ağırlık değerleri normal dağılımda rastgele olarak başlatılabilmektedir [52].

3.2 Konvolüsyonel Sinir Ağları ile Semantik Bölütleme

Derin öğrenme mimarileri kullanılarak görüntülerin sınıflandırılması (image classification), görüntüler üzerinde obje tespiti (object localization), semantik bölütleme (semantic segmentation) ve obje bazlı bölütleme (instance segmentation) yapılabilmektedir. Görüntü sınıflandırma, görüntünün hangi nesneyi veya hangi nesneleri ifade ettiğini tahmin etme işlemidir. Obje tespitinde ise yalnızca görüntüdeki objelerin isimleri değil, bunun yanında objelerin konumsal bilgisi de sınırlayıcı kutular ile

tespit edilmektedir. Semantik bölütleme problemlerinde ise görüntüdeki nesnelere ait pikseller belirli bir etiket değeri ile etiketlenmektedir. Böylelikle görüntüdeki her piksel için sınıf tahmini yapılır. Obje bazlı bölütleme ise aynı sınıfın farklı örnekleri için farklı etiketler kullanılmaktadır [53]. Şekil 3.10'da görüntü sınıflandırma, obje tespiti, semantik bölütleme ve obje bazlı bölütleme işlemleri görsel olarak açıklanmaktadır.



Şekil 3.10 Derin öğrenme mimarilerinin görüntü analizinde kullanım alanları [53]

Konvolüsyonel Sinir Ağları gibi denetimli derin öğrenme algoritmalarının, özellikle görüntü sınıflandırma ve obje tespiti gibi üst düzey görüntü analizi alanlarında oldukça başarılı olması, araştırmacıları semantik bölütleme (piksel seviyesinde etiketleme) problemlerinin Konvolüsyonel Sinir Ağları ile çözümünü araştırmaya yönlendirmiştir. Semantik bölütleme amacıyla geliştirilen derin öğrenme algoritmaları:

- U-Net
- SegNet
- DeepLab
- Fully Convolutional Network (FCN)


- ENet
- LinkNet
- Densely Connected Convolutional Network (DenseNet)
- Fully Convolutional DenseNet (Tiramisu)
- DilatedNet
- PixelNet
- ICNet
- ERFNet
- RefineNet
- Pyramid Scene Parsing Network (PSPNet)
- Deconvolution Network (DeconvNet)

olarak özetlenebilir. Sunulan çalışmada uydu görüntülerinden kıyı çizgisi amacıyla SegNet semantik bölütleme mimarisi [54] kullanılmıştır.

3.2.1 SegNet Mimarisi


SegNet mimarisi Badrinarayanan vd. tarafından yol, araba, bina gibi farklı sınıflar arasındaki renk, şekil ve doku özelliklerini modelleyerek sokak görüntülerinin semantik bölütleme uygulamaları için geliştirilmiştir [54].

SegNet mimarisi, kodlayıcı (encoder) katmanları, kodçözücü (decoder) katmanları ve piksel tabanlı sınıflandırma katmanından oluşmaktadır. Kodlayıcı katmanları, obje tespiti için geliştirilen VGG16 derin öğrenme mimarisinin [57] 13 konvolüsyon katmanından oluşmaktadır. VGG16 mimarisi Şekil 3.11’de gösterilmektedir [54].




Şekil 3.11 VGG16 mimarisi [55]

Kod çözücü katmanlarında piksel tabanlı sınıflandırma için, kodlayıcı katmanlarında üretilen düşük çözünürlüklü özellik haritalarının girdi görüntü ile aynı çözünürlüğe eşlenmesi işlemi yapılmaktadır. Kod çözücü katmanlarında doğrusal olmayan örnekleme işlemini gerçekleştirmek için, her bir kod çözücü katmanına karşılık gelen kodlayıcı katmanında yapılan maksimum havuzlama işlemi kullanılır. Maksimum havuzlama aşamasında hesaplanan havuzlama indisleri üst örnekleme yapmak amacıyla kod çözücü katmanına aktarılır. Üst örnekleme oluşturma aşaması Şekil 3.12’de açıklanmaktadır. Son olarak piksel tabanlı sınıflandırma katmanı, kod çözücü katmanlarının sonuna eklenmektedir [54]. SegNet mimarisi şekil 3.13’te gösterilmektedir.



Şekil 3.12 SegNet mimarisinde üst örnekleme oluşturma yöntemi [56]




Şekil 3.13 SegNet mimarisi [54]

Sunulan çalışmada VGG16 ve VGG19 mimarilerindeki konvolüsyon katmanları kullanılmak üzere iki farklı SegNet mimarisi test edilmiştir. VGG19 mimarisi VGG16'dan farklı olarak 16 konvolüsyon katmanına sahiptir [57].

3.3 Sayısal Kıyı Çizgisi Analizi Sistemi (Digital Shoreline Analysis System – DSAS)

Sayısal Kıyı Çizgisi Analizi Sistemi (Digital Shoreline Analysis System - DSAS), Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (United States Geological Survey – USGS) tarafından geliştirilen, Esri ArcGIS yazılımı içerisinde çalışan ücretsiz bir eklenti paketidir. DSAS, bir zaman serisinde bulunan vektör formattaki kıyı çizgisi verilerinin değişim oranı istatistiklerini hesaplamak amacıyla geliştirilmiştir [58].

Sunulan çalışmada DSAS, elde edilen kıyı çizgisinin doğruluğunu analiz etmek amacıyla kullanılmıştır. Bu amaç için elle sayısallaştırılan kıyı çizgisi ve derin öğrenme yöntemi ile elde edilen kıyı çizgisi arasında kalan dik mesafeler DSAS'ın Net Kıyı Çizgisi Hareketi (Net Shoreline Movement - NSM) modülü kullanılarak hesaplanmıştır. Şekil 3.9'da DSAS'da kullanılan referans çizgisi, kesitler ve ölçüm noktaları gösterilmektedir.



Şekil 3.9 DSAS yapısı

Elde edilen kıyı çizgisi ile elle sayısallaştırılan kıyı çizgisi arasında kalan dik mesafelerin ortalama ve karesel ortalama hataları (3.6) ve (3.7) formülleri kullanılarak hesaplanmıştır [5].

$$O.H. = \frac{1}{n} \sum_{i=1}^n |X_i| \quad (3.6)$$

$$K.O.H. = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \quad (3.7)$$

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 Donanım ve Yazılım

Sunulan çalışmada yapılan uygulamaların gerçekleştirildiği bilgisayara ait teknik özellikler aşağıda listelenmektedir.

- Model : MSI GS63VR 7RF-267XTR Stealth Pro
- İşlemci : Intel® Core™ i7-7700HQ 2.8GHz İşlemci
- Yonga Seti : Intel® HM175
- Ekran Kartı : nVidia GeForce® GTX 1060 6GB GDDR5
- Bellek : 16GB DDR4 2400MHz
- Hafıza : 128GB SSD + 1TB 7200Rpm

Çalışmada, eğitim veri setinin hazırlanması işlemleri için QGIS yazılımının 2.18.18 sürümü; SegNet ağının oluşturulması, eğitilmesi ve test edilmesi işlemleri için MATLAB yazılımının R2017b sürümü; ikili görüntülerden vektör formatta kıyı çizgisi elde edilmesi için ArcMap 10.5 ve doğruluk analizi için DSAS 4.4 ArcMap eklentisi kullanılmıştır.


4.2 Materyal

Sunulan çalışmada, 30 m konumsal çözünürlüğe ve 16-bit radyometrik çözünürlüğe sahip LANDSAT-8 uydu görüntülerinin 2. (mavi), 4. (kırmızı) ve 5. (yakın kızılötesi) bantları kullanılmıştır. LANDSAT-8 görüntülerinin teknik özellikleri Çizelge 4.1'de gösterilmektedir.

Çizelge 4.1 LANDSAT–8 görüntülerinin teknik özellikleri [59]

Bantlar	Özellikleri	Spektral Aralık (nm)
Bant 1	30m Coastal/Aerosol	435-452
Bant 2	30m Blue	452-512
Bant 3	30m Green	533-590
Bant 4	30m Red	636-673
Bant 5	30m NIR	851-879
Bant 6	100m TIR-1	1060-1119
	100m TIR-2	1150-1251
Bant 7	30m SWIR-2	2107-2294
Bant 8	15m Pan	503-676
Bant 9	30m Cirrus	1363-1384


Çalışmada, 29 tanesi eğitim için ve 5 tanesi test için olmak üzere toplam 34 tane LANDSAT–8 uydu görüntüsü kullanılmıştır. Eğitim için kullanılan görüntülerin konumları Şekil 4.1’de gösterilmektedir.



Şekil 4.1 Eğitim için kullanılan görüntülerin konumları

Birinci test görüntüsü olarak İstanbul'un kuzeyinde yer alan Terkos Gölü'ne ait uydu görüntüsü kullanılmıştır. Terkos Gölü, İstanbul'un Avrupa yakasının su ihtiyacının yaklaşık yüzde 95'ini, tüm İstanbul'un ise yaklaşık yüzde 40'ını karşılamaktadır. Karadeniz kıyı bölgesinde meydana gelen dalga ve akıntı etkilerinin yanı sıra bilimsel yöntemlere dayanmayan kum alımları ve hatalı kıyı tahkimatları nedeniyle Karadeniz tuzlu suyunun Terkos Gölü'ne nüfuz etme riski bulunmaktadır. Ayrıca Terkos kıyı bölgesi doğal ve insan kaynaklı sebeplerden dolayı erozyon tehdidi altındadır [60].


Diğer test görüntüleri, Türkiye'nin denize kıyısı olan farklı bölgelerinden seçilmiştir. Test için kullanılan görüntüler eğitim görüntüleri dahilinde bulunmayan görüntüler olup görüntülerin konumları Şekil 4.2'de gösterilmektedir.



Şekil 4.2 Test için kullanılan görüntülerin konumları

4.3 Eğitim Veri Setinin Hazırlanması

SegNet semantik bölütleme ağında eğitim verisi olarak kullanılmak üzere 250 x 250 boyutlarında görüntüler ve bu görüntülerin su ve kara sınıflarını temsil eden etiket görüntüleri elde edilmiştir. Eğitim veri setinin hazırlanmasında öncelikle mavi – kırmızı – yakın kızılötesi bant kombinasyonuna sahip 29 adet LANDSAT-8 uydu görüntüsü üzerinde, 2000 x 2000 boyutlarında parçalar kesilmiştir. Kesilen parçaların bir örneği Şekil 4.2’de gösterilmektedir.




Şekil 4.2 Eğitim verisi oluşturmak için kullanılan 2000 x 2000 boyutlarında bir görüntü örneği

Derin öğrenme ağının eğitilmesi için kullanılacak olan eğitim görüntüsünün su ve kara sınıflarını ifade eden etiket verisine ihtiyaç duyulmaktadır. Etiket verilerinin oluşturulması için elde edilen 2000 x 2000 boyutlarındaki görüntülerin NDWI görüntüleri oluşturulmuştur. NDWI, uzaktan algılama görüntüleri kullanılarak su özelliklerini belirlemek için kullanılan bir bant oranlama yöntemidir. NDWI görüntüleri (4.1) eşitliği ile hesaplanmaktadır [61].

$$NDWI = \frac{NIR-RED}{NIR+RED} \quad (4.1)$$


NDWI değerleri -1 ile +1 arasında değişmektedir. Yeşil alanlar pozitif değerlere, toprak alanları sıfıra yakın pozitif değerlere ve su özelliklerinin negatif NDWI değerlerine sahip olma eğilimi vardır [61].

Sunulan çalışmada elde edilen 2000 x 2000 boyutlarındaki NDWI görüntülerine 0 eşik değeri uygulanarak su (siyah) ve kara (beyaz) sınıflarını ifade eden ikili görüntüler oluşturulmuştur. Elde edilen ikili görüntülerden bir örnek Şekil 4.3'te gösterilmektedir.




Şekil 4.3 Su ve kara sınıflarını ifade eden ikili görüntü örneği

İkili görüntülerde oluşan gürültüler manuel olarak temizlenmiştir. Şekil 4.4'te gürültü temizleme işlemi yapılmış ikili görüntü örneği gösterilmektedir.



Şekil 4.4 Gürültü temizleme işlemi yapılmış ikili görüntü örneği

Eđitim verileri 250 x 250 boyutlarında kullanılacađı iin 2000 x 2000 boyutlarına sahip grntler ve etiket grntleri 64 paraya blnerek 250 x 250 boyutlarında grntler elde edilmiřtir (řekil 4.5).




řekil 4.5 250 x 250 boyutlarında eđitim verisi elde etme iřlemi

Elde edilen 250 x 250 boyutlarındaki grntlerde sırasıyla ařađıdaki iřlemler yapılmıřtır:

- %99'dan daha fazla oranda kara sınıfı ieren paralar, ok eřitli gri deđerlere sahip olduđundan ve bu durum ađın eđitimini verimsizleřtireceđi iin silinmiřtir.
- Mavi-kırmızı-yakın kızıltesi bant kombinasyonunda bulut glgeleri ile su sınıfına ait olan pikseller benzer gri deđerlere sahiptir. Bu durum derin đrenme ađının yanlıř eđitilmesine sebep olacađı iin bulut ieren paralar silinmiřtir.
- Veri artırma (data augmentation) yntemleri, mevcut veri setinden daha fazla veri elde etme yntemleridir. Makine đrenmesinde veri setinin sayısını ve eřitliliđini arttırmak iin sıklıkla kullanılmaktadır [62]. Sunulan alıřmada, kalan grntlere 90, 180 ve 270 derece dndrme iřlemi uygulanmıřtır. Elde edilen grntler de eđitim verilerine dahil edilerek veri artırma iřlemi gerekleřtirilmiřtir.


Bu iřlemler sonrasında toplam 4880 adet 250 x 250 boyutlarında eđitim verisi elde edilmiřtir. Eđitim verilerinden rnekler řekil 4.6'da gsterilmektedir.



Şekil 4.6 Eğitim veri setinden örnekler

4.4 SegNet Ağının Eğitimi

MATLAB yazılımı kullanılarak VGG16 ve VGG19 SegNet ağı oluşturulmuştur. Eğitim setinde bulunan sınıfların piksel sayılarındaki dengesizlik öğrenme sürecini verimsizleştirebilmektedir. Derin öğrenme mimarilerinin, sınıflandırmada baskın sınıflar lehine karar verme eğilimi bulunmaktadır [19]. Şekil 4.7’de, kullanılan eğitim setinde bulunan piksellerin frekansları gösterilmektedir.



Şekil 4.7 Eğitim setinde bulunan piksellerin frekansları

Bu problemi engellemek için eğitim sırasında minimize edilecek maliyet fonksiyonu olarak Medyan Frekans Dengeli Çapraz Entropi Fonksiyonu (Median Frequency Balanced Cross-Entropy Function) kullanılmıştır. Medyan frekans dengeleme, su ve kara sınıflarına yeni ağırlık değerleri vermektedir [63].

$$w_c = f_{median}/f_c \quad (4.2)$$


Burada w_c , c sınıfının ağırlığını; f_c , c sınıfının frekansını; f_{median} , sınıf frekanslarının medyan değerini ifade etmektedir.

SegNet ağının eğitiminde kullanılan eğitim parametreleri Çizelge 4.2’de gösterilmektedir. Eğitim parametrelerinin seçiminde, kullanılan donanımın özellikleri ve daha önce yapılan çalışmalar dikkate alınmıştır.

Çizelge 4.2 Kullanılan eğitim parametreleri


Eğitim Parametresi	Seçilen Eğitim Parametresi
Eğitim Algoritması	SGDM
Momentum	0.9
İlk Öğrenme Katsayısı	0.001
L2 Regularizasyon Katsayısı	0.0005
Maksimum Epok	100
Mini Batch Boyutu	6
Verilerin Karıştırılması	Başlangıçta 1 Karıştırma
Çalıştırma Ortamı	GPU

SegNet VGG19 ağı için eğitim işlemi 81300 iterasyonda ve yaklaşık 51 saatte tamamlanmıştır. Şekil 4.8’de SegNet VGG19 ağı için öğrenme grafiği gösterilmektedir. SegNet VGG19 ağının öğrenme grafiği incelendiğinde %90 öğrenme doğruluğu düzeyine 60000 ile 70000 iterasyonlar arasında ulaşıldığı gözlemlenmektedir.



Şekil 4.8 SegNet VGG19 öğrenme grafiği


SegNet VGG16 ağı için eğitim işlemi 81300 iterasyonda ve yaklaşık 43 saatte tamamlanmıştır. Şekil 4.9'da SegNet VGG16 ağı için öğrenme grafiği gösterilmektedir. SegNet VGG16 ağının öğrenme grafiği incelendiğinde %90 öğrenme doğruluğu düzeyine 40000 iterasyondan sonra ulaşıldığı gözlemlenmektedir. SegNet VGG16 mimarisinin SegNet VGG19 mimarisine göre daha az konvolüsyon katmanı içermesi, %90 öğrenme doğruluğu düzeyine daha erken ulaşılmasını sağlamıştır.



Şekil 4.9 SegNet VGG16 öğrenme grafiği


4.5 Kıyı Çizgilerinin Elde Edilmesi

SegNet ağının test edilmesinde 250 x 250 boyutlarında parçalar kullanılmıştır. Her bir test görüntüsü 250 x 250 boyutlarında parçalara bölünerek test edildiğinde, her bir parçanın çevresinde hatalı sonuçlar elde edildiği gözlemlenmiştir. Şekil 4.10'da her parçanın çevresinde gözlemlenen hatalı sonuçlar gösterilmektedir.




Şekil 4.10 Test görüntüsünün 250 x 250 boyutlu parçalara bölünmesi ile elde edilen ikili görüntü

Bu problemi engellemek için öncelikle girdi görüntü 200x200 boyutlarında bölünmüştür. Merkezi 200x200 boyutlarındaki görüntü parçası ile aynı olan 250x250 boyutlarındaki görüntü parçaları ağı girdi olarak verilmiştir. Elde edilen 250x250 boyutlarındaki ikili görüntünün 200x200 boyutlarındaki kısmı kaydedilmiştir. İşlem Şekil 4.11’ de özetlenmiştir.




Şekil 4.11 SegNet ağıının test edilmesinde kullanılan yöntem


SegNet VGG19 mimarisi için bu yöntem uygulanarak elde edilen ikili görüntüler Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15 ve Şekil 4.16'da gösterilmektedir. SegNet VGG16 mimarisi ile elde edilen ikili görüntüler Şekil 4.17, Şekil 4.18, Şekil 4.19, Şekil 4.20 ve Şekil 4.21'de gösterilmektedir.




Şekil 4.12 Birinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü




Şekil 4.13 İkinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü




Şekil 4.14 Üçüncü test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü




Şekil 4.15 Dördüncü test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü




Şekil 4.16 Beşinci test görüntüsü için SegNet VGG19 mimarisi ile üretilen ikili görüntü




Şekil 4.17 Birinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü




Şekil 4.18 İkinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü



Şekil 4.19 Üçüncü test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü




Şekil 4.20 Dördüncü test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü




Şekil 4.21 Beşinci test görüntüsü için SegNet VGG16 mimarisi ile üretilen ikili görüntü


Elde edilen ikili görüntüler ArcMap ortamında vektör forma dönüştürülmüştür. Yapılan vektörleştirme işlemi sonucunda elde edilen kıyı çizgileri Şekil 4.21, Şekil 4.22, Şekil 4.23, Şekil 4.24 ve Şekil 4.25'te gösterilmektedir.




Şekil 4.22 Birinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)




Şekil 4.23 İkinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)



Şekil 4.24 Üçüncü test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)




Şekil 4.25 Dördüncü test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)



Şekil 4.26 Beşinci test görüntüsü için elde edilen kıyı çizgileri (Sol: SegNet VGG19, Sağ: SegNet VGG16)

4.6 Doğruluk Analizi

Doğruluk analizi için her bir test görüntüsünden elde edilen kıyı çizgileri elle sayısallaştırılan kıyı çizgileri ile karşılaştırılmıştır. Kesitlerin üretilmesinde kullanılacak olan ana hat (baseline), elle sayısallaştırılan kıyı çizgilerine 500 metrelik tampon (buffer) uygulanarak oluşturulmuştur. Başlangıç noktaları ana hat olmak üzere 5 metrede bir olacak şekilde kıyı çizgisine dik kesit çizgileri üretilmiştir. Kesit çizgilerinin boyları 750 m olarak belirlemiştir. Şekil 4.26'da ana hat, kesitler, elle sayısallaştırılan kıyı çizgisi ve SegNet mimarisi ile elde edilen kıyı çizgisi gösterilmektedir.



Şekil 4.27 DSAS elemanları. Kahverengi: kesitler, siyah: ana hat, kırmızı: elle sayısallaştırılan kıyı çizgisi, mavi: SegNet mimarisi ile elde edilen kıyı çizgisi

DSAS'ın Net Kıyı Çizgisi Hareketi (Net Shoreline Movement - NSM) modülü kullanılarak elle sayısallaştırılan kıyı çizgisi ile SegNet mimarisi ile elde edilen kıyı çizgisi arasındaki dik mesafeler hesaplanmıştır. Hesaplanan dik mesafeler kullanılarak elde edilen ortalama hata ve karesel ortalama hata değerleri Çizelge 4.3 ve Çizelge 4.4'te gösterilmektedir.

Çizelge 4.3 SegNet VGG19 ağı için ortalama ve karesel ortalama hata değerleri.

Test Görüntüsü	Ortalama Hata (m)	Ortalama Hata (piksel)	Karesel Ortalama Hata (m)	Karesel Ortalama Hata (piksel)
1	13.38	0.45	18.61	0.62
2	16.16	0.54	22.28	0.74
3	20.32	0.68	33.75	1.13
4	9.99	0.33	18.37	0.61
5	12.62	0.42	19.68	0.66

SegNet VGG19 ağı mimarisi için, kullanılan 5 farklı test görüntüsünden elde edilen kıyı çizgilerinin ortalama hataları incelendiğinde 3. test görüntüsü haricindeki test görüntülerinde sırasıyla 13.38, 16.16, 9.99 ve 12.62 m ortalama hata elde edilmiştir. Tespit edilen ortalama hata değerlerinin $\frac{1}{2}$ piksel boyutundan daha az olduğu görülmektedir. Benzer şekilde, 3. test görüntüsü haricindeki test görüntülerinde sırasıyla 18.61, 22.28, 18.37 ve 19.68 m karesel ortalama hata elde edilmiştir. Tespit edilen karesel ortalama hata değerlerinin 1 piksel boyutundan daha az olduğu görülmektedir.

Çizelge 4.4 SegNet VGG16 ağı için ortalama ve karesel ortalama hata değerleri.

Test Görüntüsü	Ortalama Hata (m)	Ortalama Hata (piksel)	Karesel Ortalama Hata (m)	Karesel Ortalama Hata (piksel)
1	9.78	0.33	11.58	0.39
2	25.67	0.86	45.71	1.52
3	17.07	0.57	26.86	0.90
4	11.11	0.37	16.12	0.54
5	10.69	0.36	17.97	0.60

SegNet VGG16 ağı mimarisi için, sırasıyla 9.78, 25.67, 17.07, 11.11 m ve 10.69 m ortalama hata; 11.58, 45.71, 26.86, 16.12 ve 17.97 m karesel ortalama hata tespit edilmiştir. 2. Ve 3. test görüntüleri haricinde elde edilen ortalama hata değerlerinin $\frac{1}{2}$ piksel boyutundan daha az olduğu, karesel ortalama hata değerlerinin 1 piksel boyutundan daha az olduğu görülmektedir.

2. ve 3. test görüntülerinin spektral özelliklerinin kullanılan eğitim görüntülerinden farklı olması sebebi ile daha fazla hata hesaplandığı öngörülmektedir. Eğer eğitim görüntülerinin sayısı ve bununla birlikte çeşitliliği artırılırsa 2. ve 3. test görüntüleri gibi görüntülerde de verimli sonuçlar elde edilebileceği öngörülmektedir.

VGG19 yapısını kullanan SegNet mimarisinde 16, VGG16 yapısını kullanan SegNet mimarisinde ise 13 tane konvolüsyon katmanı bulunmaktadır. Üretilen kıyı çizgilerinin ortalama ve karesel ortalama hata değerleri incelendiğinde kullanılan test görüntüsü ve eğitim görüntülerinin spektral özelliklerine bağlı olarak gerekli konvolüsyon katmanı sayısının değişebildiği gözlemlenmektedir.

SegNet VGG19 ağı için ayrıntılı doğruluk analizi Çizelge 4.5’de, SegNet VGG16 ağı için ayrıntılı doğruluk analizi Çizelge 4.6’da gösterilmektedir.

Çizelge 4.5 SegNet VGG19 ağı için ayrıntılı doğruluk analizi

Test Görüntüsü	Hesaplanan Mesafe (m)	0-6	6-10	10-15	15-30	>30
1	Kesit Sayısı	1260	836	860	1449	223
	Oran (%)	27.23	18.06	18.58	31.31	4.82
2	Kesit Sayısı	1764	936	852	1491	767
	Oran (%)	30.36	16.11	14.66	25.66	13.20
3	Kesit Sayısı	1363	1033	800	1064	1021
	Oran (%)	25.81	19.56	15.15	20.15	19.33
4	Kesit Sayısı	2245	1062	704	511	195
	Oran (%)	47.59	22.51	14.92	10.83	4.13
5	Kesit Sayısı	1429	1070	957	884	235
	Oran (%)	31.23	23.39	20.92	19.32	5.14

SegNet VGG19 ağı için ayrıntılı doğruluk analizi incelendiğinde her bir test görüntüsü için elde edilen mesafelerin sırasıyla; %63.87, %61.14, %60.52, %85.03 ve %75.54’ü ½ piksel boyutundan daha az; %95.18, %86.80, %80.67, %95.87 ve %94.86’sı 1 piksel boyutundan

daha az olarak hesaplanmıştır. Buna karşın elde edilen mesafelerin sırasıyla %4.82, %13.20, %19.33 , %4.13 ve %5.14'ü 1 piksel boyutundan daha fazla olarak elde edilmiştir.

Çizelge 4.6 SegNet VGG16 ağı için ayrıntılı doğruluk analizi

Test Görüntüsü	Hesaplanan Mesafe (m)	0-6	6-10	10-15	15-30	>30
1	Kesit Sayısı	1553	1233	912	854	76
	Oran (%)	33.56	26.64	19.71	18.45	1.64
2	Kesit Sayısı	1546	842	823	1432	1118
	Oran (%)	26.84	14.62	14.29	24.86	19.41
3	Kesit Sayısı	1543	963	858	1196	721
	Oran (%)	29.22	18.24	16.25	22.65	13.65
4	Kesit Sayısı	1896	813	843	849	316
	Oran (%)	40.20	17.24	17.87	18.00	6.70
5	Kesit Sayısı	1991	962	729	647	246
	Oran (%)	43.52	21.03	15.93	14.14	5.38

SegNet VGG16 ağı için ayrıntılı doğruluk analizi incelendiğinde her bir test görüntüsü için elde edilen mesafelerin sırasıyla; %79.90, %55.74, %63.70, %75.30 ve 80.48'i ½ piksel boyutundan daha az; 98.36, 80.59, 86.35, 93.30 ve 94.62'si 1 piksel boyutundan daha az olarak hesaplanmıştır. 1 piksel boyutundan daha fazla olarak elde edilen mesafelerin oranı ise her bir test görüntüsü için sırasıyla %1.64, %19.41, %13.65, %6.70 ve %5.38'dir.

SONUÇ VE ÖNERİLER

Sunulan tezde derin öğrenme algoritmalarının uydu görüntülerinden kıyı çizgisi çıkarımı problemindeki performansı araştırılmıştır. Bu amaç için semantik bölütleme amacıyla geliştirilen SegNet derin öğrenme mimarisi kullanılarak 5 farklı LANDSAT-8 uydu görüntüsünden kıyı çizgisi çıkartılmıştır.

Derin öğrenme algoritmalarının çok fazla hesaplama kullanması sebebiyle eğitim aşamasında güçlü bir donanıma ihtiyaç duyulmaktadır. Sunulan tez çalışmasında eğitim işlemi, VGG19 yapısını kullanan SegNet ağı için yaklaşık 51 saatte, VGG16 yapısını kullanan SegNet ağı için yaklaşık 43 saatte tamamlanmıştır. Daha güçlü GPU'lar ile çalışarak eğitim veri setinin sayısı artırılabilir. Böylelikle, veri setine çeşitlilik kazandırılacağı için daha yüksek doğruluk değerleri elde edilebileceği öngörülmektedir.

Sunulan çalışmada LANDSAT-8 uydusunun mavi – kırmızı – yakın kızılötesi bant kombinasyonu kullanılmıştır. Donanım yetersizliğinden dolayı daha fazla sayıda bant kullanılamamıştır. Kızılötesi bant, su alanlarında düşük yansıma değerleri verdiği için tercih edilmiştir. Daha fazla bant kullanılması durumunda SegNet derin öğrenme ağı daha fazla özellik haritası oluşturacaktır. Bu durumun, sunulan yöntemin doğruluğunu artıracak olduğu öngörülmektedir.

Sunulan çalışmada, derin öğrenme algoritmalarının geleneksel makine öğrenmesi algoritmalarına göre en büyük avantajı olan otomatik özellik çıkarımı test edilmiştir. Herhangi bir manuel özellik çıkarımı işlemi gerçekleştirilmeden, saf veri seti kullanılarak

eđitim ve test işlemleri gerçekleştirilmiştir. SegNet derin öğrenme mimarisi kullanılarak eğitim aşamasında kullanılacak olan özellikler, konvolüsyon ve havuzlama katmanları ile otomatik olarak çıkartılmıştır. Böylelikle kullanıcının eğitim veri seti için özellik belirlemesi aşamasının önüne geçilmiştir.

Kıyı çizgilerindeki değişimin izlenmesi kıyı alanlarının yönetimi ve doğal çevre için önem arz etmektedir. Sunulan çalışmada LANDSAT-8 uydu görüntülerinden kıyı çizgisi çıkarımı için SegNet derin öğrenme mimarisinin verimli sonuçlar verdiği sonucuna ulaşılmıştır.



KAYNAKLAR

- [1] Maglione, P., Parente, C. ve Vallario, A. (2014). "Coastline extraction using high resolution WorldView-2 satellite imagery", *European Journal of Remote Sensing*, 47(1): 685-699.
- [2] Sekovski, I., Stecchi, F., Mancini, F. ve Del Rio, L. (2014). "Image classification methods applied to shoreline extraction on very high-resolution multispectral imagery", *International Journal of Remote Sensing*, 35(10): 3556-3578.
- [3] Bayram, B., Seker, D. Z., Acar, U., Yuksel, Y., Guner, H. A. A. ve Cetin, I. (2013). "An integrated approach to temporal monitoring of the shoreline and basin of Terkos Lake", *Journal of Coastal Research*, 29(6): 1427-1435.
- [4] Bayram, B., Acar, U., Seker, D. ve Ari, A. (2008). "A novel algorithm for coastline fitting through a case study over the Bosphorus", *Journal of Coastal Research*, 24(4): 983-991.
- [5] Zhang, T., Yang, X., Hu, S. ve Su, F. (2013). "Extraction of coastline in aquaculture coast from multispectral remote sensing images: Object-based region growing integrating edge detection", *Remote Sensing*, 5(9): 4470-4487.
- [6] Rishikeshan, C. A. ve Ramesh, H. (2017). "A novel mathematical morphology based algorithm for shoreline extraction from satellite images", *Geo-spatial Information Science*, 20(4): 345-352.
- [7] Lary, D. J., Alavi, A. H., Gandomi, A. H. ve Walker, A. L. (2016). "Machine learning in geosciences and remote sensing", *Geoscience Frontiers*, 7(1): 3-10.
- [8] Choung, Y. J., ve Jo, M. H. (2017). "Comparison between a Machine-Learning-Based Method and a Water-Index-Based Method for Shoreline Mapping Using a High-Resolution Satellite Image Acquired in Hwado Island, South Korea", *Journal of Sensors*, 2017, Article ID 8245204.
- [9] Goodfellow, I., Bengio, Y., Courville, A. ve Bengio, Y. (2016). *Deep Learning*, MIT Press, Cambridge.
- [10] Långkvist, M., Kiselev, A., Alirezaie, M. ve Loutfi, A. (2016). "Classification and segmentation of satellite orthoimagery using convolutional neural networks", *Remote Sensing*, 8(4): 329-349.

- [11] Panboonyuen, T., Jitkajornwanich, K., Lawawirojwong, S., Srestasathiern, P. ve Vateekul, P. (2017). "Road Segmentation of Remotely-Sensed Images Using Deep Convolutional Neural Networks with Landscape Metrics and Conditional Random Fields", *Remote Sensing*, 9(7): 680-698.
- [12] Rottensteiner, F., Sohn, G., Jung, J., Gerke, M., Baillard, C., Benitez, S. ve Breitkopf, U. (2012). "The ISPRS benchmark on urban object classification and 3D building reconstruction", *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, 1(3): 293-298.
- [13] Randrianarivo, H., Le Saux, B. ve Ferecatu, M. (2013). "Urban structure detection with deformable part-based models", *Geoscience and Remote Sensing Symposium (IGARSS)*, 21-26 July 2013, Australia.
- [14] Razakarivony, S. ve Jurie, F. (2016). "Vehicle detection in aerial imagery: A small target detection benchmark", *Journal of Visual Communication and Image Representation*, 34: 187-203.
- [15] Audebert, N., Le Saux, B. ve Lefèvre, S. (2017). "Segment-before-detect: Vehicle detection and classification through semantic segmentation of aerial images", *Remote Sensing*, 9(4): 368-385.
- [16] Xu, Y., Wu, L., Xie, Z. ve Chen, Z. (2018). "Building Extraction in Very High Resolution Remote Sensing Imagery Using Deep Learning and Guided Filters", *Remote Sensing*, 10(1): 144-161.
- [17] Gutman, G., Byrnes, R., Masek, J. ve Covington, S. (2008). "Towards monitoring land-cover and land-use changes at a global scale: the global land survey 2005", *Photogrammetric Engineering and Remote Sensing*, 74(1): 6-10.
- [18] Feng, M., Sexton, J. O., Channan, S. ve Townshend, J. R. (2016). "A global, high-resolution (30-m) inland water body dataset for 2000: First results of a topographic-spectral classification algorithm", *International Journal of Digital Earth*, 9(2): 113-133.
- [19] Isikdogan, F., Bovik, A. C. ve Passalacqua, P. (2017). "Surface Water Mapping by Deep Learning", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(11): 4909-4918.
- [20] Yang, L., Tian, S., Yu, L., Ye, F., Qian, J. ve Qian, Y. (2015). "Deep learning for extracting water body from Landsat imagery", *International Journal of Innovative Computing, Information and Control*, 11(6), 1913-1929.
- [21] El Kafrawy, S. B., Basiouny, M. E., Ghanem, E. A. ve 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] Trochta, J. T., Mouw, C. B. ve Moore, T. S. (2015). "Remote sensing of physical cycles in Lake Superior using a spatio-temporal analysis of optical water typologies", *Remote Sensing of Environment*, 171: 149-161.
- [23] Boak, E. H. ve Turner, I. L. (2005). "Shoreline definition and detection: a review", *Journal of Coastal Research*, 21(4): 688-703.

- [24] Sesli, F. A. (2006). "Sayısal Fotogrametri ile Kıyı Alanlarındaki Değişimin İzlenmesi", Jeodezi, Jeoinformasyon ve Arazi Yönetimi Dergisi, 95: 11-17.
- [25] Özyurt, G. (2012). "Yapı Denetimi Hakkında Kanun ve Bazı Kanunlarda Değişiklik Taslağı 'Kıyı Kanunu'nu Nasıl Etkiliyor?", Türkiye Mühendislik Haberleri, 474: 24-28.
- [26] Thieler, E. R., Smith, T. L., Knisel, J. M. ve Sampson, D. W. (2013). "Massachusetts Shoreline Change Mapping and Analysis Project", 2013 Update (2012-1189). Retrieved from Reston, VA: <http://pubs.er.usgs.gov/publication/ofr20121189>
- [27] Bendell, L. I. ve Wan, P. C. (2011). "Application of aerial photography in combination with GIS for coastal management at small spatial scales: a case study of shellfish aquaculture", Journal of Coastal Conservation, 15(4): 417-431.
- [28] Sale P. F., Butler IV M. J., Hooten A. J., Kritzer K. P., Lindeman K. C., Sadovy de Mitcheson Y. J., Steneck R. S., van Lavieren H. (2008). Stemming decline of the coastal ocean: rethinking environmental management. UNU-INWEH, Hamilton.
- [29] Zhang, K., Douglas, B. C. ve Leatherman, S. P. (2004). "Global warming and coastal erosion", Climatic Change, 64(1), 41-58.
- [30] Jickells T.D. ve Rae J.E. (1997). Biogeochemistry of intertidal sediments. Cambridge Environmental Chemistry Series, Cambridge University Press, Cambridge.
- [31] Liu, H., Sherman, D. ve Gu, S. (2007). "Automated extraction of shorelines from airborne light detection and ranging data and accuracy assessment based on Monte Carlo simulation", Journal of Coastal Research, 23(6): 1359-1369.
- [32] Li, R., Di, K. ve Ma, R. (2001). "A Comparative Study of Shoreline Mapping Techniques", 4th International Symposium on Computer Mapping and GIS for Coastal Zone Management , 18-20 June 2001, Halifax, Nova Scotia, Canada.
- [33] Lillesand, T., Kiefer, R. W., ve Chipman, J. (2014). Remote Sensing and Image Interpretation, Fifth Edition, John Wiley & Sons, New Jersey.
- [34] Gaur, M., Pandey, C. B. ve Goyal, R. K. (2016). Remote Sensing For Natural Resources Management & Monitoring. Scientific Publishers, Jodhpur.
- [35] Yamazaki, F. ve Liu, W. (2016). "Remote sensing technologies for post-earthquake damage assessment: A case study on the 2016 Kumamoto earthquake", 6th Asia Conference on Earthquake Engineering, 22 - 24 September 2016, Cebu City.
- [36] Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., Lingenfelder, I., Sohlbach, M. M. M., Weber, M. ve Willhauck, G. (2000). eCognition Professional User Guide 4, Defines Imaging, Munich, Germany.
- [37] Schowengerdt, R. A. (2006). Remote sensing: models and methods for image processing, Third Edition, Elsevier, New York.
- [38] Gens, R. (2010). "Remote sensing of coastlines: detection, extraction and monitoring", International Journal of Remote Sensing, 31(7): 1819-1836.
- [39] Kutser, T., Paavel, B. C., Verpoorter, C., Kauer, T. ve Vahtmäe, E. (2012). "Remote sensing of water quality in optically complex lakes", International Archives of the

Photogrammetry, Remote Sensing and Spatial, Information Sciences, XXXIX-B8, 165-169.

- [40] Patterson, J. ve Gibson, A. (2017). Deep Learning: A Practitioner's Approach, First Edition, O'Reilly Media, California.
- [41] Deep Learning, https://leonardoaraujosantos.gitbooks.io/artificial-inteligence/content/deep_learning.html, 04.05.2018.
- [42] Kenneth Lee, A Theory Explains Deep Learning, https://medium.com/@kennethlee_98497/a-theory-explains-deep-learning-79b02598a2d5, 04.05.2018.
- [43] <https://www.quora.com/How-common-is-it-for-neural-networks-to-be-represented-by-3rd-order-tensors-or-greater>, 04.05.2018.
- [44] Krizhevsky, A., Sutskever, I. ve Hinton, G. E. "ImageNet Classification with Deep Convolutional Neural Networks", NIPS 2012 : Neural Information Processing Systems Conference, 3-6 December 2012, Nevada.
- [45] Aghdam, H. H. ve Heravi, E. J. (2017). Guide to Convolutional Neural Networks: A Practical Application to Traffic-Sign Detection and Classification, Springer, New York.
- [46] Muruganandham, S., (2016). Semantic segmentation of satellite images using deep learning. Yüksek Lisans Tezi, Luleå University of Technology Department of Computer Science, Electrical and Space Engineering, Luleå.
- [47] Andrej Karpathy, Convolutional Neural Networks for Visual Recognition (Course Notes), <http://cs231n.github.io/>, 04.05.2018.
- [48] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Ruslan Salakhutdinov, R. (2014). "Dropout: A Simple Way to Prevent Neural Networks from Overfitting", Journal of Machine Learning Research, 15: 1929–1958.
- [49] Tompson, J., Goroshin, R., Jain, A., LeCun, Y., & Bregler, C. (2015). "Efficient object localization using convolutional networks", In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 648-656).
- [50] van Laarhoven, T. (2017). "L2 regularization versus batch and weight normalization", arXiv preprint arXiv:1706.05350.
- [51] Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures, Neural networks: Tricks of the trade, Springer, Berlin.
- [52] Mishkin, D. ve Matas, J. (2016). "All you need is a good init", ICLR 2016, 2 – 4 May 2016, San Juan.
- [53] Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V. ve Garcia-Rodriguez, J. (2017). "A review on deep learning techniques applied to semantic segmentation", Computing Research Repository (CoRR), abs/1704.06857.
- [54] Badrinarayanan, V., Handa, A. ve Cipolla, R. (2015). "Segnet: A deep convolutional encoder-decoder architecture for robust semantic pixel-wise labelling", arXiv preprint arXiv:1505.07293.

- [55] Pawit Kochakarn, Machine Learning with Python: Image Classifier using VGG16 Model - Part 1: Theory, <https://www.techkingdom.org/single-post/2017/11/07/Machine-Learning-with-Python-Image-Classifier-using-VGG16-Model---Coming-Soon>, 04.05.2018.
- [56] Semantic Segmentation using Fully Convolutional Networks over the years, https://meetshah1995.github.io/semantic-segmentation/deep-learning/pytorch/visdom/2017/06/01/semantic-segmentation-over-the-years.html#sec_segnet, 04.05.2018.
- [57] Simonyan, K. ve Zisserman, A. (2014). "Very deep convolutional networks for large-scale image recognition", arXiv preprint arXiv:1409.1556.
- [58] Thieler, E. R., Himmelstoss, E. A., Zichichi, J. L. ve Ergul, A. (2009). The Digital Shoreline Analysis System (DSAS) version 4.0-an ArcGIS extension for calculating shoreline change (No. 2008-1278). US Geological Survey.
- [59] Landsat 8 Overview, <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-%20overview/>, 04.05.2018.
- [60] Erdem, F., Derinpınar, M., Nasirzadehdizaji, R., Oy, S., Şeker D. Ve Bayram, B. (2018). "Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği", Geomatik, 3 (2): 100-107.
- [61] McFeeters, S. K. (1996). "The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features", International Journal of Remote Sensing, 17(7): 1425-1432.
- [62] Hauberg, S., Freifeld, O., Larsen, A. B. L., Fisher III, J. W. ve Hansen, L. K. (2016). "Dreaming More Data: Class-dependent Distributions over Diffeomorphisms for Learned Data Augmentation", 19th International Conference on Artificial Intelligence and Statistics, 9 – 11 May 2016, Cadiz, Spain.
- [63] Eigen, D. ve Fergus, R. "Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture", IEEE International Conference on Computer Vision, 7 - 13 December 2015, Santiago.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Fırat ERDEM
Doğum Tarihi ve Yeri : 05.05.1993 - Trabzon
Yabancı Dili : İngilizce
E-posta : firaterdem5@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Harita Mühendisliği	Karadeniz Teknik Üniversitesi	2016
Lise	Fen Bilimleri	Trabzon Akçaabat Anadolu Lisesi	2011

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2013	Trabzon Tapu ve Kadastro Bölge Müdürlüğü	Stajyer Mühendis
2012	Rize Çevre Yolu İnşaatı ve Rize Güneysu Yolu İnşaatı	Stajyer Mühendis

YAYINLARI

Makale

1. Erdem, F., Derinpınar, M., Nasırzadehdizaji, R., Oy, S., Şeker D. Ve Bayram, B. (2018). "Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği", Geomatik, 3 (2): 100-107. DOI: 10.29128/geomatik.362179

Bildiri

1. Bayram, B., Erdem, F., Akpınar, B., Ince, A. K., Bozkurt, S., Catal Reis, H., ve Seker, D. Z. (2017). "The Efficiency Of Random Forest Method For Shoreline Extraction From Landsat-8 And Gokturk-2 Imageries", ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., IV-4/W4, 141-145, <https://doi.org/10.5194/isprs-annals-IV-4-W4-141-2017>.
2. Demir, N., Oy, S., Erdem, F., Şeker, D. Z., ve Bayram, B. (2017). "Integrated Shoreline Extraction Approach With Use Of Rasat Ms And Sentinel-1a Sar Images", ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., IV-2/W4, 445-449, <https://doi.org/10.5194/isprs-annals-IV-2-W4-445-2017>.
3. Erdem F., Derinpınar M. A., Nasırzadehdizaji R., Oy, S., Seker D. Z. ve Bayram. B. (2017). "Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği", 9. TUFUAB Teknik Sempozyumu Bildiri Kitabı, 27-29 Nisan 2017, Afyon, Türkiye, s. 84-89.