

T.C.
İSTANBUL ÜNİVERSİTESİ
DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ

**UYDU GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ
TESPİTİNDE MAKİNE ÖĞRENMESİ
ALGORİTMALARININ PERFORMANSLARININ
DENEYSEL OLARAK KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Osman İsa ÇELİK
Denizel Çevre Ana Bilim Dalı

Danışman
Prof. Dr. Cem GAZİOĞLU

HAZİRAN, 2020

T.C.
İSTANBUL ÜNİVERSİTESİ
DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ

OSMAN İSA ÇELİK tarafından hazırlanmış ve sunulmuş “UYDU GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ TESPİTİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ PERFORMANSLARININ DENEYSEL OLARAK KARŞILAŞTIRILMASI” başlıklı tez DENİZEL ÇEVRE Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Tez Danışmanı
Prof. Dr. Cem GAZİOĞLU (D)

Jüri Üyesi
Prof. Dr. Dursun Zafer ŞEKER

Jüri Üyesi
Prof. Dr. Çiğdem GÖKSEL

Jüri Üyesi
Prof. Dr. Füsun Balık ŞANLI

Jüri Üyesi
Dr. Öğr. Üyesi Hasan Bora USLUER

Tez Savunma Tarihi: 08.07.2020

ETİK BEYAN

İstanbul Üniversitesi Deniz Bilimleri ve İşletmeciliği Enstitüsü Tez Yazım Kılavuzu kurallarına uygun olarak hazırladığım “UYDU GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ TESPİTİNDE MAKİNE ÖĞRENMEŞİ ALGORİTMALARININ PERFORMANSLARININ DENEYSEL OLARAK KARŞILAŞTIRILMASI” başlıklı YÜKSEK LİSANS tez çalışmasında bilimsel etik ve akademik kurallara riayet ettiğimi;

- Çalışma konusunun özgün olduğunu,
- Tez içinde sunduğum tüm veri ve belgeleri bilimsel etik ve ahlak kuralları çerçevesinde elde ettiğimi,
- Çalışmanın bulgularında tahrifat yapmadığımı ve yanlış davranmadığımı,
- Tez kapsamında yararlandığım tüm eserlere ve doğrudan veya dolaylı olarak kullandığım her alıntıya atıfta bulunduğumu,
- Yararlandığım tüm eserlerin kaynakçada gösterilenlerden oluştuğunu,
- Kullandığım veri ve belgelerde herhangi bir hafriyat yapmadığımı,
- Patent ve telif haklarını ihlal etmediğimi

bildirir, aksinin vuku bulması durumunda yasal sonuç/sonuçları ve aleyhime doğabilecek tüm hak kayıplarını kabul ettiğimi beyan ederim.

08.07.2020

Osman İsa Çelik

İmza

“Değerli Eşim Selin’e”



ÖNSÖZ

Makine Öğrenmesi Sınıflandırıcılarının kıyı tiplerine bağlı olarak, kıyı boyunca ne kadar isabetli tahminler yaptığı sorusu bu çalışmanın ortaya çıkmasına sebep olmuştur. Bu sebeple, sık karşılaşılan falez, sahil, yapay kıyı tipleri çalışma kapsamına dahil edilmiştir. Bu kıyı tipleri çalışmaya dahil edilirken falezler için gölge alan içeren ve içermeyen kısımlar, ve sahiller için siltli-killi ve kumlu-çakıllı sahiller ayrı olarak ele alınmıştır. Güçlü Makine Öğrenmesi sınıflandırıcıların isabetlilikleri bu kıyı tiplerine bağlı olarak detaylıca incelenmeye çalışılmıştır. Bu çalışma ile birlikte, kıyı çizgisi çıkartma işlemine sağlanan katkı ile birlikte, insanlar ve diğer birçok canlı türü için değerli kaynakları içeren ve risk altında olan kıyı alanlarının korunmasına da katkı sağlanması hedeflenmiştir.

Yüksek lisans eğitimim ve tez çalışmam süresince benden desteğini esirgemeyen ve bana yol gösteren değerli hocam Prof. Dr. Cem GAZİOĞLU başta olmak üzere tüm değerli İstanbul Üniversitesi Deniz Bilimleri ve İşletmeciliği ailesine teşekkür ederim.

Başta eşim Selin ÇELİK olmak üzere, benden desteğini hiçbir zaman esirgemeyen ve her zaman yanımda olan tüm sevdiklerime teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	i
ÖZET	iii
ABSTRACT	iv
TABLO LİSTESİ	v
ŞEKİL LİSTESİ	vi
SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
EKLER LİSTESİ	ix
1. GİRİŞ	1
2. MATERYAL VE METOT	5
2.1. Uydu Görüntüsü Kaynağı ve Çalışma Bölgesi	5
2.2. Kıyı Tipleri ve Belirleme İşaretleri	6
2.2.1. Falez	7
2.2.2. Sahil	7
2.2.3. Yapay kıyı	8
2.3. Makine Öğrenmesi Sınıflandırıcıları	9
2.3.1. Destek Vektör Makineleri	9
2.3.2. Çok Katmanlı Algılayıcı	11
2.3.3. Kolektif Öğrenme Sınıflandırıcıları	12
2.4. Metodolojik Akış	13
2.5. Görüntü İşleme	14
2.6. Veri İşleme	16
2.7. Sınıflandırıcı İşlemleri	17
2.8. İsaetlilik Değerlendirmesi	18
3. BULGULAR	21
3.1. Falezler İçin İsaetlilik Değerleri	21
3.2. Sahiller İçin İsaetlilik Değerleri	23
3.3. Yapay Kıyı İçin İsaetlilik Değerleri	24
4. TARTIŞMA VE SONUÇLAR	26
EKLER	32
EK 1. SVMs Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	32
EK 2. MLP Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	34
EK 3. Kolektif Öğrenme Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	36
ÖZGEÇMİŞ	38

ÖZET

UYDU GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ TESPİTİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ PERFORMANSLARININ DENEYSEL OLARAK KARŞILAŞTIRILMASI

Osman İsa ÇELİK

İnsanlar ve diğer canlı türleri için değerli kaynakları barındıran kıyı alanları bir çok tehlikeye karşı risk altında olan, izlenmesi ve korunması gerekli alanlardır. Kıyıların korunması ve izlenmesinde en önemli ve gerekli aşamalardan biri kıyı çizgisi çıkartma işlemidir. Bu işlem için geleneksel metotların zorlukları ve yüksek maliyetlerine karşın, gelişen uzaktan algılama teknikleri ve bilgisayar bilimleri bu işlem için araştırmacıları, Makine Öğrenmesi Sınıflandırıcılarına yönlendirmiştir. Bu konuda literatürde birçok çalışma yer almasına karşın kıyı çizgisi çıkartmada önemli etkisi olduğu bilinen kıyı tipleri özelinde yeterli inceleme bulunmamaktadır. Bu çalışma kapsamında, uydu görüntülerinden kıyı çizgisi çıkartma işlemi için başarılı bulunan Makine Öğrenmesi sınıflandırıcılarının farklı kıyı tipleri üzerinden isabetlilikleri detaylı olarak incelenmeye çalışılmıştır. İncelenen kıyı tipleri gölge alan içeren ve içermeyen falezler, killi-siltli ve kumlu çakıllı sahiller ve yapay kıyılardır. Destek Vektör Makineleri, Çok Katmanlı Algılayıcılar ve Kolektif Öğrenme Sınıflandırıcılarına ait farklı fonksiyon ve algoritmalarından oluşan 12 sınıflandırıcı bu kıyı tipleri üzerinde incelemeye tabi tutulmuştur. Çalışma sonucunda, Kolektif Öğrenme sınıflandırıcıları diğer sınıflandırıcıların genel olarak gerisinde kalmıştır. Yapay Sinir Ağlarının ve Destek Vektör Makineleri'nin birçok farklı kıyı tipinde isabetliliği gözlenirken, bilinenin aksine Sigmoid çekirdek fonksiyonun tüm kıyı tiplerinde daha başarısız olduğu kanısına varılmıştır.

Anahtar Kelimeler: Uzaktan algılama, uydu görüntüsü, kıyı çizgisi tespiti, kıyı tipleri, makine öğrenmesi

ABSTRACT

AN EMPIRICAL PERFORMANCE COMPARISON OF MACHINE LEARNING ALGORITHMS FOR DETECTING COASTLINE FROM SATELLITE IMAGES

Osman İsa ÇELİK

Coastal areas, which contain valuable resources for humans and other species, need to be monitored and protected against many dangers. One of the most important and necessary steps in the protection and monitoring of the coasts is the coastline extraction process. Despite the difficulties and high costs of traditional methods for this process, developing remote sensing techniques and computer science directed the researchers to study the Machine Learning Classifiers. Although there are many studies on this subject in the literature, there are not enough study depending on the coastal types which known to have an important effect on coastline extraction. In this study, it was tried to study the accuracy of machine learning classifiers on different coast types in detail, which were found successful for coastline extraction from satellite images. The coastal types studied include cliffs with and without shaded areas, clayey-silty and sandy gravel beaches and artificial coasts. 12 classifiers consisting of different functions and algorithms belonging to Support Vector Machines, Multi-layer Perceptron's and Ensemble Learning classifiers were examined on these coast types. As a result of the study, Ensemble Learning classifiers achieved lower accuracy in all studied coast types compared to other classifiers. While Artificial Neural Networks and Support Vector Machines achieved high accuracy in many different coast types, it was found that the Support Vector Machines using the Sigmoid kernel function achieved the lowest accuracy in all coast types.

Keywords: Remote sensing, satellite image, coastline extraction, coast types, machine learning

TABLO LİSTESİ

	Sayfa
Tablo 1. Çalışmada kullanılan Sentinel-2A MSI uydu görüntüsüne ait bant bilgileri.	5
Tablo 2. Referans kıyı çizgisi üzerinde ayrılan kıyı tiplerinin konumları ve uzunlukları.	19
Tablo 3. Gölge içermeyen falez için sınıflandırıcılara ait isabetlilik sonuçları.	21
Tablo 4. Gölge Alan içeren falez için sınıflandırıcılara ait isabetlilik sonuçları.	22
Tablo 5. Killi-Siltli sahil için sınıflandırıcılara ait isabetlilik sonuçları.	23
Tablo 6. Kumlu-Çakıllı sahil için sınıflandırıcılara ait isabetlilik sonuçları.	24
Tablo 7. Yapay kıyı için sınıflandırıcılara ait isabetlilik sonuçları.....	25



ŞEKİL LİSTESİ

	Sayfa
Şekil 1. Çalışmada kullanılan Sentinel-2A MSI uydu görüntüsü. (A) Tüm görüntü (ESA (European Space Agency), 2020'den alınmıştır.). (B) Çalışma Alanı.....	5
Şekil 2. Çalışma kapsamında seçilen alanlar. (A) Sınıflandırıcı eğitim alanı. (B) Tahmin ve doğrulama alanı.....	6
Şekil 3. Çalışmada incelenen kıyı tipleri.	6
Şekil 4. Falez görselleri. (A) Gölge alan içermeyen falez. (B) Gölge alan içeren falez.	7
Şekil 5. Sahil görselleri. (A) Killi-siltli sahil. (B) Kumlu-çakıllı sahil.....	8
Şekil 6. Yapay kıyı görseli.....	9
Şekil 7. İki boyutlu düzlemde uygun kenar boşluğu ve uygun hiper düzlem gösterimi (Cortes ve Vapnik, (1995)'ten alınmıştır.)	10
Şekil 8. Çok Katmanlı Algılayıcılar'a ait genel tahmin yapısı (Rumelhart ve diğerleri (1985)'ten alınmıştır.).....	11
Şekil 9. Bu çalışma kapsamında takip edilen metodolojik akış.....	14
Şekil 10. İşlenmiş görüntüler (A-B) Sırasıyla, eğitim ve sınama alanlarına ait yanlış renkli görüntü (False Color Image)'ler. (C-D) Sırasıyla, eğitim ve sınama alanlarına ait gri tonlamalı NDWI görüntüleri.....	15
Şekil 11. Görüntü işleme sonucunda elde edilen ikili görüntüler (beyaz ve siyah alanlar sırası ile su ve kara sınıflarını göstermektedir.). (A) Eğitim Alanı. (B) Sınama Alanı.....	16
Şekil 12. Eğitim alanı dahilindeki, bant verileri ve çıktı sınıfları arasındaki korelasyon değerleri.....	17
Şekil 13. Referans kıyı çizgisi üzerinde ayrılan kısımların başlangıç noktasına uzaklıkları.....	18

SİMGE LİSTESİ

B02	: 2 Numaralı Bant (458-523 nanometre Dalga Boyu Aralığı)
B03	: 3 Numaralı Bant (543-578 nanometre Dalga Boyu Aralığı)
B04	: 4 Numaralı Bant (650-680 nanometre Dalga Boyu Aralığı)
B08	: 8 Numaralı Bant (785-899 nanometre Dalga Boyu Aralığı)
Y	: Çıktı Verisi
'	: Dakika
o	: Derece
C	: Destek Vektör Makineleri için Düzenleme Parametresi
n, o	: Eleman Sayısı
e	: Euler Sabiti
X	: Girdi Verisi
s	: İşaret Katsayısı (± 1)
d	: Kıyı Çizgileri Arasındaki Bölgesel Mesafe Farkı
D	: Kıyı Çizgileri Arasındaki Genel Mesafe Farkı
m	: Metre
nm	: Nanometre
p	: Olasılık
μ	: Ortalama
E	: Örnek
A	: Sapma Gözlenen Alan
L	: Sapma Gözlenen Referans Kıyı Çizgisi Uzunluğu
σ	: Standart Sapma
β_0, β_1	: Şekil Kontrol Parametreleri
T	: Transpoz

KISALTMA LİSTESİ

AdaB	: Adaptive Boosting (Uyarlanabilir Arttırma)
ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
CDM	: Coastline Difference Measurement (Kıyı Çizgisi Fark Ölçümü)
CFS	: Correlation-based Feature Selection (Korelasyon Tabanlı Özellik Seçimi)
D	: Doğu
ETM	: Enhanced Thematic Mapper (Geliştirilmiş Tematik Haritalayıcı)
ET	: Extra Trees (Ekstra Ağaçlar)
GB	: Gradient Boosting (Gradyan Arttırma)
Tanh	: Hiperbolik Tanjant fonksiyonu
I	: Identity (Birim)
ISODATA	: Iterative Self-Organizing Data (Yinelenen Öz-Düzenleyici Veriler)
K	: Kuzey
L	: Logistic (Mantıksal)
MLP	: Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
MSI	: Multi-spectral Instrument (Çok Bantlı Algılayıcı)
NDWI	: Normalized Difference Water Index (Normalleştirilmiş Fark Su İndeksi)
P	: Polinom
p-val	: Probability Value (Olasılık Değeri)
RBF	: Radial Basis Function (Radyal Tabanlı Fonksiyon)
RF	: Random Forest (Rastgele Karar Ormanları)
ReLu	: Rectified Linear Units (Düzeltilmiş Lineer Birimler)
SVMs	: Support Vector Machines (Destek Vektör Makineleri)
TM	: Thematic Mapper (Tematik Haritalayıcı)

EKLER LİSTESİ

	Sayfa
EK 1. SVMs Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	32
EK 1.1. SVMs-L için Fark Değerleri.	32
EK 1.2. SVMs-P için Fark Değerleri.	32
EK 1.3. SVMs-R için Fark Değerleri.	33
EK 1.4. SVMs-S için Fark Değerleri.	33
EK 2. MLP Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	34
EK 2.1 MLP-I için Fark Değerleri.	34
EK 2.2. MLP-L için Fark Değerleri.	34
EK 2.3. MLP-T için Fark Değerleri.	35
EK 2.4. MLP-R için Fark Değerleri.	35
EK 3. Kolektif Öğrenme Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar	36
EK 3.1. RT için Fark Değerleri.	36
EK 3.2. ET için Fark Değerleri.	36
EK 3.3. GB için Fark Değerleri.	37
EK 3.4. AdaB için Fark Değerleri.	37

1. GİRİŞ

Kıyı alanları, deniz ve kara ekosistemlerinin kesiştiği, insan nüfusunun yaklaşık %60'ının yaşadığı ve diğer birçok canlı türü ile paylaştığı alanlardır. İnsanlar için değerli ekonomik ve doğal kaynaklar içeren bu alanlar, gittikçe artan nüfus ve iklim değişikliği sonucu artan su seviyeleri sebebiyle tehlike altındadır (Thia-Eng, 1993; Vitousek ve diğerleri, 1997). Kıyı alanlarının sürdürülebilir olarak planlanması ve kıyı ekosisteminin korunması için kıyı alanlarının izlenmesi büyük önem arz etmektedir (Alesheikh ve diğerleri, 2007). Kıyı alanların takibinde temel gereksinimlerden biri kıyı çizgisinin tespiti ve haritalanmasıdır. Kıyı çizgisi tespiti kıyı bilimleri, kıyı mühendisliği, kıyı planlaması ve yönetimi gibi birçok farklı disiplinde kullanılmaktadır (Dolan ve diğerleri, 1991). Kıyı yapılarının inşası, sayısal modellerin kalibrasyonu ve kontrolü, kıyı düzenleme politikalarının ve yasal mülk sınırlarının belirlenmesi, vb. uygulamalar da aynı şekilde kıyı çizgisi tespitini gerektirmektedir (Boak ve Turner, 2005).

Kıyı çizgisi en yaygın kullanımı ile kara ve su kütlelerini fiziksel olarak ayıran ara yüz olarak tanımlanmaktadır. Bu tanım ile birlikte, oluşturulan kıyı çizgisi için kullanılacak referans kotu seçiminde farklı göstergeler ile farklı tanımlamalar da mevcuttur. Genel olarak kullanılan göstergeler; anlık görülen, farklı su seviyesi durumlarına bağlı ve kıyı çizgisi çıkartmada tercih edilen görüntü işleme tekniğine bağlı olacak şekilde 3 gruba ayrılmaktadır (Boak ve Turner, 2005; Crowell ve diğerleri, 1991; Teodoro, 2016). Kıyı çizgileri antropojenik etkiler (kıyı yapıları, dolgular, kıyı beslemeleri, ekonomik ve sosyal faaliyetler vb.) ve doğal etkiler (dalgalar, rüzgarlar, yakın kıyı akıntıları, gel-git, vb.) etkilere sıkça maruz kalmaları sebebiyle dinamik bir yapıya sahiptirler (Teodoro, 2016). Bu dinamik yapı bazı durumlarda kıyı çizgisinin sıklıkla yeniden tespitini gerekli kılmaktadır.

Kıyı çizgisi haritalama işlemi 200 yılı aşkın bir süredir, başta yer gözlemleri ve ardından hava fotoğrafları kullanılarak gerçekleştirilmiştir. Kullanılan geleneksel metotlar yüksek maliyet, zaman ve insan gücü gerektirmekte, ayrıca kıyıların zorlu geometrik ve spektral yapıları sebebiyle fazlaca hata barındırmaktaydılar (Li ve diğerleri, 2001). Bu işlemi daha az zahmet ve maliyetle yapmaya olanak veren uydu görüntüleri geleneksel yöntemlere kıyasla daha fazla tercih edilmeye başlanmıştır. 1972'de başta Landsat olmak üzere uydu görüntüleri ile kızıl ötesi bantlara ait verilerin temini, kıyı çizgisi çıkartmada uydu görüntülerinin

kullanımını daha makul hale getirmiş ve daha isabetli sonuçlar ortaya çıkartmıştır (Alesheikh ve diğerleri, 2007; Gens, 2010).

Uydu görüntülerinden kıyı çizgisi çıkartma amacıyla birçok farklı metot denenmiştir. Bu teknikler genel olarak; görüntü işleme teknikleri, kontrollü ve kontrolsüz sınıflandırma teknikleri olarak gruplandırılabilir (Abd Manaf ve diğerleri, 2017). Kullanılan görüntü işleme tekniklerinden bazıları; Normalleştirilmiş Fark Su İndeksleri (Normalized Difference Water Index (NDWI)) (Su ve diğerleri, 2016), Bant Oranlama (Band Rationing) (Kuleli, 2010), Segmentasyon (Segmentation) (Dellepiane ve diğerleri, 2004), Kenar Tespiti (Edge Detection), Eşikleme (Thresholding) (Liu ve Jezek, 2004), Dalgacık Dönüşümü (Wavelet) (Niedermeier ve diğerleri, 2000) gibi yöntemlerdir (Sekovski ve diğerleri, 2014). Görüntü işleme tekniklerinin yanı sıra uydu görüntülerinden kıyı çizgisi çıkartma ve kara-su kütlelerinin sınıflandırılması amacıyla, kontrolsüz sınıflandırıcılar (ISODATA (Shenbagaraj ve diğerleri, 2014), vb.) ve kontrollü sınıflandırıcılar (En Büyük Olabilirlik Kestirimi (Maximum Likelihood) (Rokni ve diğerleri, 2015), Mahalonobis Mesafesi (Mahalonobis Distance) (Sekovski ve diğerleri, 2014), Destek Vektör Makineleri (Support Vector Machines)) (Kalkan ve diğerleri, 2013; Zhang ve diğerleri, 2013), Yapay Sinir Ağları (Artificial Neural Networks) (Manaf ve diğerleri, 2018; Ryan ve diğerleri, 1991), Karar Ağaçları (Decision Trees) ve Kolektif Öğrenme (Ensemble Learning) metotları (Abd Manaf ve diğerleri, 2017; Bayram ve diğerleri, 2017)) da yaygın olarak kullanılmakta ve gittikçe daha fazla araştırmacının ilgisini çekmektedir.

Kontrollü sınıflandırıcıların, girdi ve örnek çıktı verileri arasında bağlantıları değerlendirerek hesap ağırlıklarını güncelleyip, hiç görmedikleri örnekler üzerinde başarılı tahminler yapabilmeleri bir öğrenme sürecine benzetilmekte ve Kontrollü Makine Öğrenmesi Sınıflandırıcıları olarak da anılmaktadırlar (Alpaydin, 2020; Pereira ve diğerleri, 2009). Uzaktan algılama ile temin edilebilen yüksek alansal çözünürlüklü ve zengin spektral aralığa (Teodoro, 2016) sahip uydu görüntüleri, Kontrollü Makine Öğrenmesi Sınıflandırıcıları ile kıyı çizgisi tespitini cazip hale getirmektedir (Choung ve Jo, 2017). Birçok araştırmacı uydu görüntülerinden kıyı çizgisi tespitinde başta Destek Vektör Makineleri, Yapay Sinir Ağları ve Kolektif Öğrenme sınıflandırıcıları olmak üzere Makine Öğrenmesi sınıflandırıcılarına çalışmalarında yer vermiştir ve çeşitli performans kıyaslamalarında bulunmuşlardır (Kalkan ve diğerleri, 2013).

Destek Vektör Makineleri, kıyı çizgisi çıkartma işlemi üzerine yapılan çalışmalarda sıklıkla tercih edilmektedir. Choung ve Jo (2017), Destek Vektör Makineleri ve NDWI görüntü işleme tekniğini kullanılarak yüksek çözünürlüklü (10m çözünürlüklü) WorldView-2 uydu görüntülerinden çıkartılan kıyı çizgilerinin isabetliliklerini kıyaslamıştır. Referans kıyı çizgisi ile mesafe farkları üzerinden yapılan kıyaslamada Destek Vektör Makineleri'nin daha isabetli tahminlerde bulunduğunu belirtmiştir. Zhang ve diğerleri (2013), Destek Vektör Makineleri için 3 farklı çekirdek fonksiyonu kullanarak farklı kıyı tipleri (falez, siltli, kumlu, yapay ve mangrov kaplı) üzerinden, Landsat7-ETM (30m çözünürlüklü) ve Pankromatik (15m çözünürlüklü) uydu görüntülerinden kıyı çizgileri çıkartmış ve kıyaslamıştır. Yaptığı kıyaslamada tahmin performanslarını doğru tahmin edilen piksel yüzdeleri üzerinden vermiş ve Sigmoid çekirdek fonksiyonunun tüm kıyı tiplerinde daha başarılı olduğu kanısına varmıştır.

Yapay Sinir Ağları kullanarak kıyı çizgisi çıkartma amacı ile yapılan çalışmalarda başarılı sonuçlara rastlanmaktadır. Ryan ve diğerleri (1991) hava fotoğrafları üzerinde Yapay Sinir Ağları ve görüntü işleme teknikleri kullanarak gerçekleştirdiği kıyı çizgisi çıkartma çalışmasında başarılı sonuçlar elde etmiş ve gelecek çalışmalara yön vermiştir. Manaf ve diğerleri (2018), Yapay Sinir Ağları için farklı Aktivasyon fonksiyonları ile orta çözünürlüklü (30m çözünürlüklü) Landsat-TM uydu görüntülerinden kıyı çizgileri çıkartmış ve diğer sınıflandırıcılar ile performanslarını kıyaslamıştır. Kıyı tipinden bağımsız olarak ve doğru tahmin edilen piksellerin yüzdesi ile yapılan kıyaslama neticesinde Yapay Sinir Ağları'nın (ReLU aktivasyon fonksiyonu ile) diğer sınıflandırıcılara üstünlüğünden bahsedilmiştir.

Kolektif Öğrenme (Ensemble Learning) sınıflandırıcıları ile Karar Ağacı (Decision Tree) gibi zayıf sınıflandırıcılar kullanılarak güçlü tahminler oluşturulabilmektedir. Elde edilen başarılı sonuçlar neticesinde, araştırmacılar bu yöntemi kıyı çizgisi çıkartma üzerinde de kullanmışlardır. Bayram ve diğerleri (2017), Terkos Gölü çevresinde ve Karadeniz ile kesişen yakın kıyılarda, Landsat-8 orta çözünürlüklü uydu görüntüleri üzerinden Rastgele karar ormanları (Random Forests) sınıflandırıcısı ile kıyı çizgisi çıkartmıştır. Farklı bant kombinasyonları denenerek gerçekleştirilen çalışmada özellikle yakın kızıl ötesi bantlar ile yapılan denemelerde yakın sonuçlar elde edilmiştir. Abd Manaf ve diğerleri (2017), orta çözünürlükte Landsat TM görüntüleri üzerinden çeşitli Kolektif Öğrenme sınıflandırıcılarını birbirleri ile ve diğer sınıflandırıcılar ile kıyaslamıştır. Kıyı tipinden bağımsız olarak ve doğru tahmin edilen piksellerin yüzdesi ile yapılan kıyaslama neticesinde, Yapay Sinir Ağları'nın

ardından en yüksek başarılar 4 farklı Kolektif Öğrenme sınıflandırıcı tarafından elde edilmiştir. Bu sınıflandırıcılar, başarı sırasına göre, Gradyan Arttırma (Gradient Boosting), Uyarlanabilir Arttırma (Adaptive Boosting), Rastgele Karar Ormanları (Random Forests) ve Ekstra Ağaçlar (Extra Trees)'dan oluşmaktadır.

Kıyı tiplerine bağlı olarak, kıyılar farklı spektral özellikler göstermektedir ve bu durum kullanılan makine öğrenmesi sınıflandırıcısının isabetliliğini etkilemektedir (Zhang ve diğerleri, 2013). Örneğin siltli ya da kumlu kıyılarının düşük eğimli yapısı sebebiyle kara-su arasındaki farkın ayırt edilebilmesi zorlaşmaktadır, buna karşılık yapay kıyılar ve falezlerde bu fark daha kolay ayırt edilebilmektedir (Ge ve diğerleri, 2014; Xukai ve diğerleri, 2012). Aynı şekilde falezlerin dik yapısı sebebiyle oluşan gölge alanları içeren görüntüler yanlış sınıflandırılmalara sebep olabilmektedir (Choung ve Jo, 2017).

Yapılan çalışmalar Makine Öğrenmesi Sınıflandırıcılarının Uydu Görüntülerinden kıyı çizgisi çıkartma işleminde verimliliğini göstermesine karşın kıyı tiplerine bağlı olarak isabetliliklerinin değerlendirilmesinde çok az veri sağlamaktadır. Aynı zamanda çalışmalarda kullanılan isabetlilik ölçüm yöntemleri farklılık göstermekte ve çoğu tahmin edilen kıyı çizgisini vektörel olarak incelemek yerine tüm görüntü üzerinden değerlendirme yapmaktadır. Bu durumun kara ve su sınıfları arasında geçişin olduğu kıyı çizgileri boyunca yanlış değerlendirmeye sebep olması olasıdır (Ge ve diğerleri, 2014).

Makine Öğrenmesi Sınıflandırıcılarının kıyı tiplerine bağlı olarak, kıyı boyunca ne kadar isabetli tahminler yaptığı sorusu bu çalışmanın ortaya çıkmasına sebep olmuştur. Bu sebeple, sık karşılaşılan falez, sahil, yapay kıyı tipleri çalışma kapsamına dahil edilmiştir. Bu kıyı tipleri çalışmaya dahil edilirken falezler için gölge alan içeren ve içermeyen kısımlar, ve sahiller için siltli-killi ve kumlu-çakıllı sahiller ayrı olarak ele alınmıştır.

Makine Öğrenmesi Sınıflandırıcıları, Destek Vektör Makineleri, Çok Katmanlı Algılayıcılar ve Kolektif Öğrenme Sınıflandırıcıları olmak üzere 3 ana gruba ayrılmıştır. Gruplar dahilinde farklı formül ve sınıflandırıcılar ile birlikte toplam 12 kıyı çizgisi çıkartılmış ve kıyı tiplerine göre isabetlilikleri incelenmiştir. İncelemede yanlışlığı azaltmak adına, birbirinden bağımsız ve gerekli tüm kıyı tiplerini ayrı ayrı içeren alanlardan elde edilen veri setleri kullanılmıştır. İncelemede referans olarak alınacak kıyı çizgileri kullanıcı denetiminde ve görüntü işleme teknikleri yardımıyla elde edilen ikili görüntülerden çıkartılmıştır.

2. MATERYAL VE METOT


2.1. Uydu Görüntüsü Kaynağı ve Çalışma Bölgesi

Çalışmada Sentinel-2A Çok Bantlı Algılayıcı (Multispectral Instrument (MSI)) yüksek çözünürlüklü uydu görüntüsü kullanılmıştır (Şekil 1-A). Kullanılan görüntü, 36° 00'K–37° 01'K Kuzey enlemleri ile 29° 37'D–30° 53'D boylamları arasını kapsamakta ve 22.01.2020 tarihine aittir. Çalışmada kullanılan görüntüye ait bant bilgileri Tablo 1'de verilmiştir.

Tablo 1. Çalışmada kullanılan Sentinel-2A MSI uydu görüntüsüne ait bant bilgileri.


Bant	Spektral Bölge	Dalga Boyu Aralığı (nm)	Algılayıcı	Mekansal Çözünürlük
B02	Mavi	458-523	S2 MSI	10 m
B03	Yeşil	543-578		
B04	Kırmızı	650-680		
B08	Yakın Kızıl Ötesi	785-899		

Çalışma bölgesi olarak Türkiye'nin Güneyinde yer alan Antalya'nın Demre İlçesi tercih edilmiştir. Kullanılan sınıflandırıcıların eğitim ve tahmin süreçlerini birbirlerinden ayırmak amacıyla, bölgede komşu iki alan eğitim ve tahmin doğrulaması için ayrılmıştır. Eğitim alanı 29° 56'D – 29° 57'D ve 36° 12'K – 36° 13'K koordinatları arasındaki 4 km²'lik bir alanı, tahmin ve doğrulama alanı ise 29° 57'D – 30° 00'D ve 36° 11'K – 36° 14'K koordinatları arasındaki 16 km²'lik bir alanı içermektedir (Şekil 1-B).



Şekil 1. Çalışmada kullanılan Sentinel-2A MSI uydu görüntüsü. (A) Tüm görüntü (ESA (European Space Agency), 2020'den alınmıştır.). (B) Çalışma Alanı.

Bölgenin tercih edilme sebebi, çalışmada incelenmesi planlanan kıyı tiplerini bir arada bulunduran bir kıyı şeridinde sahip olmasıdır. Eğitim ve tahmin doğrulaması için ayrılan alanların (Şekil 2-A ve Şekil 2-B) ikisi de, bir sonraki bölümde detaylıca anlatılacak olan; falez, sahil ve yapay kıyılara sahiptir.



Şekil 2. Çalışma kapsamında seçilen alanlar. (A) Sınıflandırıcı eğitim alanı. (B) Tahmin ve doğrulama alanı.

2.2. Kıyı Tipleri ve Belirleme İşaretleri

Çalışma kapsamında, ilgili araştırmalarda en sık tercih edilen ve Dünya genelinde kıyılarda en çok rastlanan kıyı tiplerine yer verilmeye çalışılmıştır (Emery ve Kuhn, 1982; Flemming, 2002; Mineur ve diğerleri, 2012). Çalışılan kıyı tipleri morfolojik özellikleri bakımından Falez, sahil ve yapay kıyı olmak üzere 3 ana başlıkta toplanmıştır (Şekil 3).




Şekil 3. Çalışmada incelenen kıyı tipleri.

Spektral farklılıkları bakımından ise falez, gölge alan içeren ve içermeyen falez, sahil ise killi-siltli ve kumlu-çakıllı sahil olmak üzere alt başlıklara ayrılmıştır.

2.2.1. Falez

Yaygın olarak gözlenebilen bu kıyı tipi Dünya genelindeki okyanus kıyılarının yaklaşık %80'ini oluşturmaktadır (Emery ve Kuhn, 1982). Tektonik hareketler sonucu yükselen ana kayanın dalga ve rüzgar gibi dış etkiler ile şekil alması ile oluşan falezler dar ve dik bir morfolojik yapıya sahiptir (Erinç, 2010). Oluşturdukları kıyı çizgileri, özellikle sahillere kıyasla geometrik yapılarını uzun süre muhafaza etmektedir. Uydu görüntülerinde, falezlerin sahip olduğu kaya ve bitki dokuları bu kıyı tipinin görsel olarak belirlenmesini kolaylaştırmaktadır (Şekil 4-A).

Kaya ve bitki örtüleri ile su arasındaki sıcaklık farkı, kızıl ötesi bantların kıyı çizgisi çıkartma işleminde etkisini arttırmaktadır (Zhang ve diğerleri, 2013). Buna karşılık, falezlerin dik yapısı sebebiyle görüntülerde gölge alanlar oluşabilmektedir (Şekil 4-B). Gölge alanlar kara ve su arasındaki sıcaklık farkı ile birlikte kızıl ötesi bantların etkisini de azalmakta ve çıkartılan kıyı çizgilerinde hatalara sebep olmaktadır (Choung ve Jo, 2017). Bu sebeple çalışma kapsamında sınıflandırıcıların isabetlilikleri değerlendirilirken her iki durum için ayrı bulgular elde edilip, sınıflandırıcıların isabetlilikleri değerlendirilmiştir.



Şekil 4. Falez görselleri. (A) Gölge alan içermeyen falez. (B) Gölge alan içeren falez.


2.2.2. Sahil

Sahiller çoğunlukla fiziksel etkiler (dalga, rüzgar, sıcaklık farkı, vb.) ile parçalanmış kayaçların ve/veya organik maddelerin dalga, akıntı, akarsular vb. yollarla taşınıp biriktirilmesi ile meydana gelen kıyılardır (Erinç, 2010; Flemming, 2002). İnsanlar ve diğer bir çok canlı türü

için değerli olan bu kıyılar aynı zamanda dış etkilere karşı hassas, korunması ve takip edilmesi gereken alanlardır.

Farklı sınıflandırmalara yer verilse de genel olarak, nominal çapları 2mm'den büyük olan taneler çakıl veya kaba kum, 50 μ -2mm arası kum, 2 μ m-50 μ m arası silt ve 2 μ m'den küçük taneler ise kil olarak sınıflandırılmaktadır (Verheye ve Ameryckx, 1984; Zuo ve diğerleri, 2017). Uydu görüntülerinde, siltli-killi sahiller için ince tane çapına bağlı olarak artan koheziv özellik ve su muhtevası ile birlikte daha koyu bir doku ortaya çıkartmaktadır. Kumlu-çakıllı sahiller ise bunun tam tersine yüksek parlaklığa sahip bir görüntü oluşturmaktadır.

Sahillerin düşük eğimli yapısı, kara-su ayrımını güçleştirmektedir. Sığ su altında kalan karalar ve yoğun su içeren kıyılar spektral özellikler arasında bir geçişe sebep olmaktadır ve bu durum kıyı çizgisi çıkartma işleminde hataya sebep olabilmektedir.(Zhang ve diğerleri, 2013). Bunun dışında, özellikle kumlu kıyılarda askıdaki katı maddeler ayrımı zorlaştıran bir diğer etkidir. Çalışma kapsamında sahiller, siltli-killi sahil (Şekil 5-A) ve kumlu-çakıllı sahil (Şekil 5-B) olmak üzere iki alt başlıkta incelenmiş ve sınıflandırıcıların isabetlilikleri değerlendirilmiştir.



Şekil 5. Sahil görselleri. (A) Killi-siltli sahil. (B) Kumlu-çakıllı sahil.

2.2.3. Yapay kıyı

İnsan nüfusunun artması ile birlikte kıyı alanlarında yer alan yapıların sayısı da gün geçtikçe artmaktadır (Mineur ve diğerleri, 2012). Mahmuzlar, dalgakıranlar, kıyı koruma yapıları vb. bir çok yapı kıyılarda yer almakta ve kıyı çizgisi çıkartma çalışmalarında incelenen kıyı şeritlerine dahil olmaktadır.

Uydu görüntülerinde yapay kıyılar çoğunlukla taş ve/veya beton dokusu ve sahip oldukları düzgün geometriler ile kolaylıkla ayırt edilebilmektedir (Şekil 6) (Zhang ve diğerleri, 2013). Spektral açıdan taş yapılar falezler ile beton yapılar ise kumlu-çakıllı kıyılar ile benzerlik göstermektedir (Ge ve diğerleri, 2014).



Şekil 6. Yapay kıyı görseli.

2.3. Makine Öğrenmesi Sınıflandırıcıları


Çalışma kapsamında incelenen Makine Öğrenmesi Sınıflandırıcıları, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı (veya Yapay Sinir Ağı) ve Kolektif Öğrenme Sınıflandırıcıları olarak 3 başlıkta toplanmıştır. Destek Vektör Makineleri için 4 çekirdek fonksiyonu, Çok Katmanlı Algılayıcı için 4 aktivasyon fonksiyonu ve 4 farklı Kolektif öğrenme sınıflandırıcısı ile toplamda 12 adet kıyı çizgisi oluşturulmuş ve kıyı tiplerine göre isabetlilikleri değerlendirilmiştir.

Kullanılan sınıflandırıcılar “Python” programlama diline ait “Scikit-Learn” modülünden elde edilmiştir. Scikit-learn, kontrollü ve kontrolsüz çeşitli modern Makine Öğrenmesi algoritmalarını birleştiren, bir modüldür (Buitinck ve diğerleri, 2013; Pedregosa ve diğerleri, 2011). Modülde faydalanan sınıflandırıcılar için bahsedilen değerler dışında sınıflandırıcı parametreleri mevcut halleri ile kullanılmıştır.

2.3.1. Destek Vektör Makineleri

Destek Vektör Makineleri (Support Vector Machines (SVMs)), yüksek boyutlu uzayda bir veya bir dizi hiper-düzlem (hyper-plane) oluşturarak sınıflandırma, regresyon vb. işlemleri gerçekleştirir. En uygun hiper-düzlemi oluşturabilmek için ayırım sınırlarına yakın verilerden destek vektörleri oluşturur ve en uygun kenar boşluklarını (optimal margin) elde etmeye çalışır

(Boser ve diğerleri, 1992; Cortes ve Vapnik, 1995; Ladicky ve Torr, 2011). Oluşturulan bu hiper-düzlem iki boyutlu uzayda basitçe, lineer ya da lineer olmayan çizgileri ifade etmektedir (Şekil 7).



Şekil 7. İki boyutlu düzlemde uygun kenar boşluğu ve uygun hiper düzlem gösterimi (Cortes ve Vapnik, (1995)'ten alınmıştır.)

Destek Vektör Makineleri hiper-düzlem oluşturmak amacıyla çekirdek (kernel) fonksiyonlarından faydalanmaktadır. Çekirdek fonksiyonu olarak, sınıflandırma probleminin yapısına göre farklı fonksiyonlar kullanılmaktadır. Bu çalışma kapsamında Destek Vektör Makineleri için, benzer çalışmalar (Kalkan ve diğerleri, 2013; Zhang ve diğerleri, 2013)'da tercih edilen 3 farklı çekirdek fonksiyonu ve ek olarak Lineer çekirdek fonksiyonları işlemlerde kullanılmıştır. İşlemlerde kullanılan fonksiyonlar Lineer, Polinom (Polynomial), Radyal Tabanlı Fonksiyon (Radial Basis Function (RBF)) ve Sigmoid fonksiyonlardan oluşmaktadır (Scholkopf ve Smola, 2001). Lineer ve Polinom fonksiyonlar (denklem (2.1) ve denklem (2.2)) birbirlerine benzer olmak ile birlikte Polinom derecesini gösteren “d” parametresi ile ayrılmaktadırlar. Çalışmada üçüncü dereceden Polinom çekirdek fonksiyonu tercih edilmiştir. Radyal Tabanlı fonksiyon (denklem (2.3)) için “ σ ” çekirdek fonksiyonunun genişliğini belirleyen serbest bir parametreyi, Sigmoid fonksiyon (denklem (2.4)) için ise β_0 ve β_1 , fonksiyonun şeklini kontrol etmeye yarayan parametreleri ifade eder.

$$K(x_1, x_2) = x_1^T x_2 \quad (2.1)$$

$$K(x_1, x_2) = (x_1^T x_2 + 1)^d \quad (2.2)$$


$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (2.3)$$

$$K(x_1, x_2) = \tanh(\beta_0 x_1^T x_2 + \beta_1) \quad (2.4)$$

Çalışmanın ilerleyen kısmında Destek Vektöre Makineleri'nden bahsedilirken kullanılan çekirdek fonksiyonlarını (Linear, Polynomial, RBF ve Sigmoid) ifade edecek şekilde SVMs-L, SVMs-P, SVMs-R ve SVMs-S kısaltmaları kullanılmıştır.

2.3.2. Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcı (Multi-Layer Perceptron (MLP)), Yapay Sinir Ağları (Artificial Neural Networks (ANN))'na ait bir sınıfa dahil olan bir makine öğrenmesi modelidir. Öğrenme işlemi esnasında verilen girdi grubu üzerinden ($X = x_1, x_2, \dots, x_n$), hedef gruba ($Y = y_1, y_2, \dots, y_o$), ulaşmak üzere, sınıflandırma veya regresyon amacıyla bir yaklaşım fonksiyonu kullanır. Bu tanımda “n” girdi grubu boyutunu “o” ise çıktı grubu boyutunu ifade etmektedir. Girdi ve çıktı katmanları arasında bir veya daha fazla katman içerebilmektedir (Şekil 8). Bu katmanlar, Gizli Katmanlar (Hidden Layers veya Hidden Units) olarak adlandırılmaktadır (Barber ve Bishop, 1998; Bishop, 1996; Funahashi, 1989; Rumelhart ve diğerleri, 1985).



Şekil 8. Çok Katmanlı Algılayıcılar'a ait genel tahmin yapısı (Rumelhart ve diğerleri (1985)'ten alınmıştır.)

Çok Katmanlı Algılayıcılar'da girdi verilerine ait ağırlıklar ve yanlılık (bias) değerleri hesaba katılarak bir toplam elde edilir. İşlem sonucu elde edilen toplamlar önceden belirlenen bir aktivasyon fonksiyonu kullanılarak sıradaki katmana aktarılır (Sharma, 2017). Bu çalışma kapsamında, Çok Katmanlı Algılayıcılar için benzer çalışmalar (Manaf ve diğerleri, 2018; Ryan ve diğerleri, 1991)'da da kullanılan 3 farklı Aktivasyon Fonksiyonu ve ek olarak Birim aktivasyon fonksiyonu incelenmiştir. Kullanılan fonksiyonlar, Birim (Identity) fonksiyonu (denklem (2.5)), Sigmoid veya Mantıksal (Logistic) fonksiyon (denklem (2.6)), Hiperbolik Tanjant fonksiyonu (denklem (2.7)) ve Düzeltilmiş Lineer Birim (Rectified Linear Units (ReLU)) fonksiyonu (denklem (2.8))'dur. Çalışmanın kalan kısmında Çok Katmanlı Sınıflandırıcılar, MLP-I, MLP-L, MLP-T ve MLP-R kısaltmaları ile kullanılan aktivasyon fonksiyonlarını (Identity, Logistic, Tanh ve ReLU sırası ile) belirtecek şekilde ifade edilmiştir.

$$f(x) = x \quad (2.5)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.6)$$

$$f(x) = \tanh(x) \quad (2.7)$$

$$f(x) = \max(0, x) \quad (2.8)$$

2.3.3. Kolektif Öğrenme Sınıflandırıcıları

Kolektif Öğrenme Sınıflandırıcıları, düşük tahmin kapasitesine sahip sınıflandırıcıların tahminlerini başarılarına göre ağırlıklandırarak başarılı tahmin modelleri oluşturan sınıflandırıcılardır (Zhang ve Ma, 2012). Çalışma kapsamında kullanılan Kolektif Öğrenme Sınıflandırıcıları, Rasgele Karar Ormanları (Random Forests (RF)), Ekstra Ağaçlar (Extra Trees (ET)), Uyarlanabilir Arttırma (Adaptive Boosting (AdaB)) ve Gradyan Arttırma (Gradient Boosting (GB)) sınıflandırıcılarıdır. Seçilen modeller, zayıf sınıflandırıcı olarak Karar Ağacı (Decision Tree (Brodley ve Utgoff, 1995)) kullanılmaktadırlar.

Rastgele Karar Ormanları (Random Forests (RF)), çok sayıda Karar Ağacı kullanılarak, güçlendirilmiş tahminler yapmak üzere geliştirilmiş bir Kolektif Öğrenme (Ensemble learning) modelidir. RF'nin tahminlerindeki hatalar ağaç sayısı arttıkça belirli bir limit değerine


yakınsamaktadır (Breiman, 1999). Her bir tahmin ağacı girdi veri setinden rastgele seçilmiş bir alt-veri seti kullanmaktadır. Her ağaç için kullanılan eğitim setleri birbirinden farklı olacak şekilde rastgele örneklenmiştir (Oshiro ve diğerleri, 2012; Shi ve Horvath, 2006). Modelde ağaç sayısındaki artış, modelin tahmin gücü ile birlikte işlem süresini de arttırmaktadır. Bu sebeple ayarlama işlemi için en yüksek tahmini yapan en az ağaç sayısı aranmıştır.

Ekstra Ağaçlar (Extra Trees (ET)) modeli, RF modeline oldukça benzer bir yapıdadır. RF modelinden 2 önemli farkı bulunmaktadır. Bu farklardan ilki, ET modelinde her bir karar ağacı için rastgele örnekleme işlemi yerine tüm girdi veri seti kullanılarak eğitim işlemi yapılır. İkinci olarak ise, tahmin ağaçlarının yapısındaki dallanmalar yukarıdan-aşağıya rastgele olarak belirlenmektedir (Geurts ve diğerleri, 2006). Modelin tahmin başarısını geliştirme amacıyla RF modelinde olduğu gibi en yüksek tahmini veren en düşük ağaç sayısı belirlenmeye çalışılmıştır.

Arttırma (Boosting) algoritmaları, veri seti üzerinden farklı dağılımlar üreterek kullandığı zayıf sınıflandırıcılar ile tahminler üretir ve hatayı minimize edecek şekilde üretilen tahminlerin kombinasyonları ile güçlü bir tahmin modeli oluşturur (Freund ve diğerleri, 1996). Gradyan Arttırma (Gradient Boosting (GB)) algoritmasında sınıflandırıcı tahminleri kademeli olarak azaltılırken, Uyarlanabilir Arttırma (Adaptive Boosting(AdaB)) algoritmasında zayıf tahmin edilen sınıfların ağırlıkları arttırılıp, zayıf sınıflandırıcıların ağırlıkları azaltılarak en iyi modeller oluşturulmaya çalışılır (Dietterich, 2000; Freund ve diğerleri, 1996; Margineantu ve Dietterich, 1997).

2.4. Metodolojik Akış

Çalışma 4 temel bölümden oluşmaktadır (Şekil 9). İlk aşamada görüntüler işleminden geçirilerek ilgili bölgelere ait veriler ayrılıp, kullanıcı denetiminde çıktı sınıfları oluşturulmuştur. İkinci bölümde girdi ve çıktı verileri işlemlerden geçirilerek sınıflandırıcıların kullanımına hazırlanmıştır. Üçüncü aşamada sınıflandırıcılar hazırlanıp, tahminleri elde edilerek çalışmanın amacı olan isabetlilik değerlendirme işlemi için bulgular elde edilmiştir. Son adımda ise tahmin edilen kıyı çizgileri kıyı tiplerine göre ayrılarak sınıflandırıcıların isabetlilikleri değerlendirilmiştir.



Şekil 9. Bu çalışma kapsamında takip edilen metodolojik akış.


2.5. Görüntü İşleme

Görüntü işleme aşamasının amacı, eğitim ve sınama alanlarındaki piksel koordinatlarına karşılık gelecek şekilde bantlara ait girdi verilerini tüm uydu görüntüsünden ayırmak ve kara-su sınıflandırmalarını içeren çıktı verilerini oluşturmaktadır. Görüntü işleme aşaması “Blue Marble Geographics” firması tarafından üretilen “Global Mapper v.20.0” yazılımı kullanılarak gerçekleştirilmiştir.

İlk aşamada, uydu görüntüsünden eğitim ve sınama alanlarını içeren kısımlara karşılık gelen görüntüler kesilmiş ve bölgeler ana görüntüden ayrılmıştır (Şekil 2). Ardından kullanıcı denetiminde çıktı sınıfları elde edilmiştir. Bu işlemde görsel yorumlamayı kolaylaştırmak amacıyla yanlış renkli görüntü (false color image) ve Normalleştirilmiş Fark Su İndeksleri (Normalized Difference Water Index (NDWI)) sonuçları ile oluşturulmuş gri tonlamalı görüntüler kullanılmıştır. Yanlış renkli görüntüler üretilirken görüntüdeki Kırmızı, Yeşil ve

Mavi deęerleri sırasıyla yakın kırmızı ötesi, kırmızı ve yeşil bantları ile deęiştirilerek karaların daha belirgin olduęu görüntüler elde edilmiştir (Şekil 10-A ve Şekil 10-B). NDWI deęerleri denklem (2.9) (McFeeters (2013)'ten alınmıştır.) yardımı ile hesaplanmıştır. Bu denklemde Green ve NIR sırasıyla, yeşil ve yakın kırmızıötesi spektral bölgelerine karşılık gelen bant deęerlerini ifade etmektedir. Elde edilen veriler 0-255 arasında ölçeklendirilip gri tonlamalı görüntüler oluşturulmuştur (Şekil 10-C ve Şekil 10-D).

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (2.9)$$



Şekil 10. İşlenmiş görüntüler (A-B) Sırasıyla, eğitim ve sına alanlarına ait yanlış renkli görüntü (False Color Image)'ler. (C-D) Sırasıyla, eğitim ve sına alanlarına ait gri tonlamalı NDWI görüntüleri.

Esas görüntü ve işlenmiş görüntüler yardımıyla, kullanıcı denetiminde ikili görüntüler elde edilmiştir (Şekil 11-A ve Şekil 11-B).




Şekil 11. Görüntü işleme sonucunda elde edilen ikili görüntüler (beyaz ve siyah alanlar sırası ile su ve kara sınıflarını göstermektedir.). (A) Eğitim Alanı. (B) Sınama Alanı.

2.6. Veri İşleme

Veri işleme aşamasının amacı, uydu görüntüsünden elde edilmiş bantları ve çıktı sınıflarını içeren ikili görüntüleri işlemekten geçirerek sınıflandırıcıların kullanımına hazırlamaktır.

Bu amaçla ilk önce sınıflandırıcıların tahminlerindeki hatalı yönelimi engellemek amacıyla girdi verilerini içeren bantlar üzerinde seçme işlemi gerçekleştirilmiştir. Kullanılacak bantların belirlenmesi amacıyla, Korelasyon Tabanlı Özellik Seçimi (Correlation-based Feature Selection (CFS)) metodu (Hall, 1999) kullanılmıştır. CFS metodu gereği, eğitim alanı sınırlarındaki tüm bantlara ait girdi verileri ve çıktı verileri arasındaki korelasyon değerleri belirlenmiştir (Şekil 12). Korelasyon değerlerinin belirlenmesinin ardından, çıktı verileri ile en yüksek mutlak korelasyon değerini (0.83) gösteren yakın kızıl ötesi bant değerleri birincil girdi grubu olarak seçilmiştir. İkincil girdi grubu olacak bandın seçiminde ise çıktı verileri ile yüksek mutlak korelasyon değerini (>0.50) gösteren gruplar arasından, birincil girdi grubu ile en düşük korelasyonu (0.72) gösteren yeşil bant verileri tercih edilmiştir. Girdi gruplarının seçilmesinin ardından girdi verilerinin içinden kullanılmayacak bant grupları (Mavi ve Kırmızı) elenmiştir.



Şekil 12. Eğitim alanı dahilindeki, bant verileri ve çıktı sınıfları arasındaki korelasyon değerleri.

Girdi verileri üzerinde son olarak bir ölçeklendirme işlemi gerçekleştirilmiştir. Bu işlem ile sınıflandırıcıların ağırlık katsayısı hesaplamaları esnasında ortaya çıkabilecek abartılı sonuçların önüne geçilmesi hedeflenmiştir. İşlem gereği girdi verileri 0 ile 1 arasında bir ölçeklendirmeye tabi tutulmuştur ve girdi verilerine son halleri verilmiştir.

2.7. Sınıflandırıcı İşlemleri

Bu aşamada sınıflandırıcıların hiper-parametreler (hyper parameters)'inin ayarlanması, sınıflandırıcıların eğitim bölgesinden elde edilen girdi ve çıktı verileri ile eğitilmesi ve son olarak ise sınama alanına ait bant değerlerini kullanarak tahmin işlemleri gerçekleştirilmiştir.

Tahminlerinde en iyi performansları elde edebilmek adına sınıflandırıcıların her biri için ayarlama (tuning) işlemleri gerçekleştirilmiştir. Ayarlama işlemlerinde, parametrelere karşılık gelen başarıları belirlemek amacıyla, eğitim verileri üzerinde doğrulama (validation) işlemleri gerçekleştirilmiştir. Doğrulama işleminde, K-Çapraz Katman Doğrulama (K-Fold Cross Validation) (Kohavi, 1995) uygulanmıştır. Doğrulama işlemindeki “K” ifadesi veri setinin bölüneceği grup sayısını ifade etmektedir. Bu çalışmada, eğitim girdi veri seti önceden rastgele karıştırılarak 5 eşit parçaya ayrılmıştır. Bu parçalar eşit sayıda kara ve su çıktı sınıflarını içermektedir. Bölünmüş veri setleri üzerinde 4 adet veri grubu, ayarlama katsayısının mevcut değeri ile eğitilmiş ve kalan 1 adet veri seti ile sınanmıştır. Bu işlem her 5 veri grubu için tekrar

edilmiştir ve ortalama başarıları denenen katsayı değerinin başarıları olarak alınmıştır. Her bir model için denenen katsayı değerleri içerisinde en yüksek başarıyı gösteren değerler o model için çalışmanın kalan kısmında kullanılmak üzere seçilmiştir.

Ayarlama işlemleri ile SVMs sınıflandırıcıları için Düzenleme Parametre (Regularization Parameter (C))'leri denenmiş ve SVMs-L, SVMs-P, SVMs-R, SVMs-S için sırasıyla 145, 114, 56 ve 2 değerleri elde edilmiştir. MLP sınıflandırıcıları için gizli katman sayıları değiştirilerek denemeler yapılmıştır ve MLP-I, MLP-L, MLP-T, MLP-R için sırasıyla 13, 2, 2 ve 31 gizli katman sayıları modeller için seçilmiştir. Son olarak Kolektif Öğrenme modelleri için farklı karar ağacı sayıları denenerek, RF, ET, GB ve AdaB sınıflandırıcıları için 77, 300, 130 ve 87 adet karar ağacı kullanılarak eğitim ve tahmin işlemlerine geçilmiştir.

Eğitim alanına ait bant verileri kullanarak sınıflandırıcılar eğitilmiş ve tahmine hazır hale getirilmiştir. Sınama alanına ait bant verileri ile yapılan tahminlerin sonucunda her bir sınıflandırıcının tahminleri ikili görüntüler haline getirilmiştir.

2.8. İsaletlilik Değerlendirmesi

Ana işlemlerin gerçekleştirilmesi ve tahmin sonuçlarının elde edilmesinin ardından çalışmanın son aşaması olarak sınıflandırıcıların farklı kıyı tiplerinde elde ettiği isabetlilikler belirlenmiş ve değerlendirilmiştir. İsaletlilik değerlendirme işlemini gerçekleştirebilmek amacıyla, öncelikle doğrulama alanı için kullanıcı denetiminde oluşturulan ve model tahminleri ile elde edilen ikili görüntülerden vektör kıyı çizgileri çıkartılmıştır. Araştırma kapsamında kıyı tiplerine göre isabetlilik değerlerinin belirlenmesi hedeflendiğinden çıkartılan tüm kıyı çizgisi kıyı tiplerine göre ayrılmıştır (Şekil 13).



Şekil 13. Referans kıyı çizgisi üzerinde ayrılan kısımların başlangıç noktasına uzaklıkları.

Ayrılan konumlara karşılık gelen kıyı tipleri ve uzunlukları Tablo 2’de gösterilmiştir.

Tablo 2. Referans kıyı çizgisi üzerinde ayrılan kıyı tiplerinin konumları ve uzunlukları.

Kıyı Tipi	Özellik	Başlangıç	Bitiş	Uzunluk (km)	Toplam (km)
Falez	Gölge Alan İçermeyen	0+000	1+910	1,91	3,55
		3+070	3+770	0,70	
		7+500	7+990	0,49	
	Gölge Alan İçeren	7+990	8+440	0,45	
Sahil	(Siltli-Killi)	1+910	3+070	1,16	3,58
	(Kumlu-Çakıllı)	8+440	10+860	2,42	
Yapay	-	3+770	7+500	3,73	3,73
Toplam (km)					10,86

Tahminlerden elde edilen kıyı çizgilerinin, referans alınan kıyı çizgisi ile aralarındaki kıyı boyu farklar modellerin tahminlerindeki isabet performanslarını belirlemek amacıyla incelenmiştir. Tahmin edilen ve referans alınan kıyı çizgileri arasındaki mesafeleri ölçmek amacıyla fark ölçüm işlemi gerçekleştirilmiştir. Bu işlem için Kıyı Çizgisi Fark Ölçümü (Coastline Difference Measurement (CDM)) yöntemi kullanılmıştır. CDM yöntemi, aynı bölgeye ait 2 kıyı çizgisi arasındaki mesafe farklarının hızlıca ve pratik bir şekilde ölçülebilmesi amacıyla oluşturulmuştur (Çelik ve Gazioğlu, 2020).

CDM yöntemi uygulanırken, el ile çıkartılan kıyı çizgileri referans kıyı çizgileri olarak, model tahminlerinden elde edilen kıyı çizgileri ise fark kıyı çizgileri olarak kabul edilmiştir. Kıyı çizgilerinin birbirleri ile kesiştiği noktalar belirlenmiştir ve belirlenen kesişim noktaları arasında referans kıyı çizgilerinden sapmaları içeren kısımlar fark bölgeleri (differential parts) olarak adlandırılmıştır.

Bölgesel fark (d)’ların büyüklük ve yönlerinin belirlenebilmesi amacıyla fark bölgelerinde referans kıyı çizgisi ve fark kıyı çizgisi arasında kalan alan (A)’lar hesaplanmıştır. Hesaplanan alanların ilgili fark bölgesine ait referans kıyı uzunluğu (L)’na bölünmesi ile yanlış tahmin edilmiş alanda 1 m’de oluşan ortalama farklar elde edilmiştir (denklem (2.10) (Çelik ve Gazioğlu (2020)’ndan alınmıştır.)).

$$d = s \frac{A}{L} \quad (2.10)$$

Denklemdede kullanılan işaret katsayısı (s) farkın su tarafında olması halinde +1 değerini, kara tarafında olması halinde ise -1 değerini alarak farkın yönünün daha rahat anlaşılmasını sağlamaktadır. Elde edilen farklar kıyı uzunluğu boyunca grafikler yardımıyla daha rahat gözlenebilmektedir.

Elde edilen farklar üzerinde, tahminlerdeki sapmaların yönünü (kara veya su yönünde) görebilmek amacıyla en büyük sapmalar belirlenmiştir. Bunun yanı sıra isabetlilik belirlemek amacıyla farkların ortalamaları (μ) ve tahminlerin tutarlılığını görmek amacıyla da standart sapma (σ) değerleri her bir sınıflandırıcı için hesaplanarak tablolar halinde verilmiştir.

3. BULGULAR

Sınıflandırıcılar için tüm referans kıyı şeridi boyunca elde edilen farklar Ek 1 Ek 2 ve Ek 3'te verilmiştir.

3.1. Falezler İçin İsaletlilik Değerleri

Falezler için elde edilen isabetlilik sonuçlarında, kıyıda gölge alanların yer almasına bağlı olarak, tüm sınıflandırıcılar için belirgin farklar gözlenmiştir. Gölge alanlar sınıflandırıcıların kara piksellerini su olarak tahmin etmesine sebep olmuştur ve tüm sınıflandırıcılar için en büyük negatif farklar bu alanda gözlenmiştir. Gölge alan içermeyen kısımlarda sınıflandırıcılar genel olarak isabetli ve birbirlerine yakın farklar göstermesine karşın, gölge alan içeren kısımlarda tüm sınıflandırıcılar için olumsuz bir isabetlilik farkı meydana gelmiştir (Tablo 3 ve Tablo 4). Bu farklılığa en iyi uyum sağlayan sınıflandırıcılar Lineer, Logaritmik, ve Tanh aktivasyon fonksiyonlarını kullanan Çok Katmanlı Algılayıcılar olmuştur

Tablo 3. Gölge içermeyen falez için sınıflandırıcılara ait isabetlilik sonuçları.

Destek Vektör Makineleri				
Sınıflandırıcı	SVMs-L	SVMs-P	SVMs-R	SVMs-S
Maksimum Fark (m)	+10,00	+10,00	+10,00	-10,00
μ (m)	0,29	0,23	0,32	-0,79
σ (m)	1,30	1,42	1,36	2,75
Çok Katmanlı Algılayıcı				
Sınıflandırıcı	MLP-I	MLP-L	MLP-T	MLP-R
Maksimum Fark (m)	+10,00	+10,00	+10,00	+10,00
μ (m)	0,32	0,32	0,32	0,32
σ (m)	1,36	1,36	1,36	1,36
Kollektif Öğrenme				
Sınıflandırıcı	RF	ET	GB	AdaB
Maksimum Fark (m)	+10,00	+10,00	+10,00	$\pm 5,00$
μ (m)	0,39	0,36	0,42	0,26
σ (m)	1,49	1,45	1,52	1,66

Çok Katmanlı Algılayıcılar, gölge içermeyen falezlerde aktivasyon fonksiyonundan bağımsız olarak aynı isabetliliği göstermişlerdir. Gölge alanların görüntüye dahil olması ile birlikte ReLU aktivasyon fonksiyonu için isabetlilikte bir düşüş gözlenmiştir.

Destek Vektör Makineleri için, Lineer ve RBF çekirdek fonksiyonları falezlerde gölge alanların sebep olduğu zorluğa en iyi uyum sağlayan fonksiyonlar olmuştur. SVMs-L ve SVMs-R, MLP-R fonksiyonuna çok yakın sonuçlar elde etmişlerdir. Polinom ve Tanh aktivasyon çekirdek fonksiyonları gölge alanlar ile birlikte büyük bir isabetlilik kaybı yaşamışlardır.

Tablo 4. Gölge Alan içeren falez için sınıflandırıcılara ait isabetlilik sonuçları.

Destek Vektör Makineleri				
Sınıflandırıcı	SVMs-L	SVMs-P	SVMs-R	SVMs-S
Maksimum Fark (m)	±10,00	-11,43	±10,00	±10,00
μ (m)	0,22	-1,33	0,22	0,44
σ (m)	4,39	6,00	4,39	6,21
Çok Katmanlı Algılayıcı				
Sınıflandırıcı	MLP-I	MLP-L	MLP-T	MLP-R
Maksimum Fark (m)	±10,00	±10,00	±10,00	±10,00
μ (m)	0,00	0,00	0,00	0,22
σ (m)	4,31	4,31	4,31	4,39
Kollektif Öğrenme				
Sınıflandırıcı	RF	ET	GB	AdaB
Maksimum Fark (m)	±10,00	±10,00	±10,00	±10,00
μ (m)	0,22	0,44	-0,22	0,22
σ (m)	5,85	5,46	5,95	5,37

Kollektif öğrenme sınıflandırıcıları, gölge alanlarda isabetliliklerini korumalarına karşın standart sapma değerleri büyük artış göstermiştir. Gölge alan içermeyen kıyılarda AdaB sınıflandırıcısı tarafından büyük bir isabetlilik ve tutarlılık gösterirken gölge alanların etkisiyle sonuçlarında daha büyük sapmalar meydana gelmiştir. Bu gruptaki sınıflandırıcılar birbirine yakın ve ortalama sayılabilecek sonuçlar vermiştir. Sınıflandırıcı grubunun içinde AdaB sınıflandırıcısı falezler için nispeten en iyi isabetlilikleri göstermiştir.

3.2. Sahiller İçin İsabetlilik Değerleri

Sahiller için isabetlilikler incelendiğinde, Kollektif Öğrenme Sınıflandırıcıları ve Sigmoid çekirdek fonksiyonlu Destek Vektör Makineleri'nin isabetlilikleri beklendiği gibi sığ su altında kalan ve askıdaki katı maddelerden belirgin bir şekilde olumsuz etkilenmiştir. Başta SVMs-L olmak üzere, kalan sınıflandırıcılar bu etkilerin üstesinden daha başarılı bir şekilde gelmiştir (Tablo 5 ve Tablo 6)

Destek Vektör Makineleri için Sigmoid çekirdek fonksiyonu hem killi-siltli hem de kumlu çakıllı sahillerde diğer çekirdek fonksiyonları ve denen tüm sınıflandırıcılar içinde en düşük performansı göstermiştir. Tüm sınıflandırıcılar genelinde en büyük pozitif fark SVMs-S sınıflandırıcısının tahminlerinde gözlenmiştir. Lineer çekirdek fonksiyonu ise Killi-siltli sahillerde tüm MLP sınıflandırıcıları ve SVM-P ve SVM-R ile birlikte en iyi performansı göstermiş ve Kumlu-çakıllı sahillerde de diğer tüm sınıflandırıcıları geride bırakarak sahil kıyıların genelinde büyük bir isabetlilik elde etmiştir.

Tablo 5. Killi-Siltli sahil için sınıflandırıcılara ait isabetlilik sonuçları.

Destek Vektör Makineleri				
Sınıflandırıcı	SVMs-L	SVMs-P	SVMs-R	SVMs-S
Maksimum Fark (m)	+5,00	+5,00	+5,00	+16,79
μ (m)	0,17	0,17	0,17	9,27
σ (m)	0,92	0,92	0,92	6,42
Çok Katmanlı Algılayıcı				
Sınıflandırıcı	MLP-I	MLP-L	MLP-T	MLP-R
Maksimum Fark (m)	+5,00	+5,00	+5,00	+5,00
μ (m)	0,17	0,17	0,17	0,17
σ (m)	0,92	0,92	0,92	0,92
Kollektif Öğrenme				
Sınıflandırıcı	RF	ET	GB	AdaB
Maksimum Fark (m)	+13,33	+13,33	+13,33	+13,33
μ (m)	2,24	1,72	2,33	1,81
σ (m)	3,95	3,87	4,01	3,66

Çok Katmanlı Algılayıcılar, kumlu çakıllı kıyılarda isabetlilik bakımından SVMs-L'in az bir farkla gerisinde olmasına karşın, sahil kıyıları genelinde isabetli ve tutarlı kabul edilebilecek sonuçlar elde etmişlerdir. Killi-Siltli kıyılarda aktivasyon fonksiyonlarına karşılık

isabetliliklerde farklılık gözlenmezken, kumlu-çakıllı kıyılarda, falezlerin aksine ReLU aktivasyon fonksiyonu diğer fonksiyonları geride bırakmıştır.

Kollektif Öğrenme sınıflandırıcıları Killi-siltli sahillerde, kumlu-çakıllı sahillere kıyasla nispeten daha başarılı olmasına karşın sahiller genelinde düşük isabetli ve daha tutarsız tahminlerde bulunmuşlardır. kıyılar genelinde en büyük farklar, SVMs-S sınıflandırıcının ardından bu sınıflandırıcı gurubuna ait tahminlerde gözlenmiştir. Killi-Siltli sahillerde ET, AdaB'den az bir farkla, grup içindeki en isabetli tahminleri yapmıştır. Kumlu-çakıllı sahillerde ise AdaB'nin gruptaki diğer sınıflandırıcılara isabetlilik bakımından üstünlüğü gözlenmiştir.

Tablo 6. Kumlu-Çakıllı sahil için sınıflandırıcılara ait isabetlilik sonuçları.

Destek Vektör Makineleri				
Sınıflandırıcı	SVMs-L	SVMs-P	SVMs-R	SVMs-S
Maksimum Fark (m)	±5,00	-6,67	-6,67	+15,37
μ (m)	-0,37	-1,03	-1,03	10,99
σ (m)	1,95	2,09	2,43	3,23
Çok Katmanlı Algılayıcı				
Sınıflandırıcı	MLP-I	MLP-L	MLP-T	MLP-R
Maksimum Fark (m)	±5,00	±5,00	±5,00	±5,00
μ (m)	-0,70	-0,74	-0,70	-0,53
σ (m)	1,96	2,00	1,96	1,91
Kollektif Öğrenme				
Sınıflandırıcı	RF	ET	GB	AdaB
Maksimum Fark (m)	+7,50	+10,00	+6,67	+10,00
μ (m)	4,20	5,51	4,03	3,21
σ (m)	2,62	3,67	2,61	3,26

3.3. Yapay Kıyı İçin İsabetlilik Değerleri

Yapay kıyılarda beklendiği gibi tüm sınıflandırıcılar için daha tutarlı ve yüksek isabetlilikler elde edilmiştir. Sınıflandırıcılar genelinde hatalar, su sınıflarının kara sınıfı olarak tahmin edilmesi ile pozitif yönlü olarak gözlenmiştir (Tablo 7).

Destek Vektör Makineleri için Sigmoid fonksiyon diğer aktivasyon fonksiyonları ve kalan tüm sınıflandırıcılara kıyasla daha isabetsiz tahminler yapmıştır. Destek Vektör Makineleri için en isabetli tahmin Polinom çekirdek fonksiyonu kullanan SVMs-P

sınıflandırıcısı ile elde edilmiştir. Sınıflandırıcı grubu genelinde en büyük farklar +10 m olarak gözlenmiştir.

Çok Katmanlı Algılayıcılar da ise aktivasyon fonksiyonundan bağımsız olarak, sınıflandırıcılar genelinde en isabetli tahminler gözlenmiştir. Birim (Identity) aktivasyonu kullanan MLP-I sınıflandırıcısı gruptaki diğer sınıflandırıcılara kıyasla az da olsa daha isabetsiz tahminler elde etmiştir. Sınıflandırıcı grubu genelinde en büyük farklar +5 m olarak gözlenmiştir.

Kolektif Sınıflandırıcılar, özellikle sahil kıyı çizgilerinde elde etiklerinden daha isabetli sonuçlar elde etmişlerdir. Diğer sınıflandırıcı gruplarına kıyasla ise sonuçlar daha isabetsizdir. Sınıflandırıcı grubu içinde birbirlerine yakın isabetlilikler ve tutarlılıklar elde edilmiş olup, ET sınıflandırıcı diğer Kolektif Öğrenmesi sınıflandırıcılarının az bir farkla önüne geçmiştir.

Tablo 7. Yapay kıyı için sınıflandırıcılara ait isabetlilik sonuçları.

Destek Vektör Makineleri				
Sınıflandırıcı	SVMs-L	SVMs-P	SVMs-R	SVMs-S
Maksimum Fark (m)	+10,00	+10,00	+10,00	+10,00
μ (m)	0,27	0,19	0,38	0,80
σ (m)	1,22	1,12	1,39	2,75
Çok Katmanlı Algılayıcı				
Sınıflandırıcı	MLP-I	MLP-L	MLP-T	MLP-R
Maksimum Fark (m)	+5,00	+5,00	+5,00	+5,00
μ (m)	0,19	0,16	0,16	0,16
σ (m)	0,93	0,86	0,86	0,86
Kolektif Öğrenme				
Sınıflandırıcı	RF	ET	GB	AdaB
Maksimum Fark (m)	+7,50	+10,00	+7,50	+7,50
μ (m)	0,48	0,46	0,59	0,51
σ (m)	1,53	1,54	1,69	1,57

4. TARTIŞMA VE SONUÇLAR

Çok Katmanlı Algılayıcılar veya Yapay Sinir Ağları sınıflandırıcılarının, Manaf ve diğerleri (2018) ve Ryan ve diğerleri (1991)'nin çalışmalarında işaret ettikleri gibi uydu görüntülerinden kıyı çizgisi çıkartma işleminde kullanımı başarılı sonuçlar vermektedir. Kullanılan aktivasyon fonksiyonu ve kıyı tiplerine bağlı olarak MLP sınıflandırıcılarının performansı etkilemekle beraber Manaf ve diğerleri (2018)'nin belirttiğinin aksine, incelenen fonksiyonların herhangi birinde genel olarak belirgin bir üstünlükten söz etmek çok güçtür. Özellikle gölgeli alan içeren falezlerde ve yapay kıyılarda diğer modellere kıyasla en isabetli ve tutarlı sonuçlar bu sınıflandırıcı grubu ile elde edilmiştir. Sahil tiplerinde çok başarılı sonuçlar elde edilmesine karşın kumlu-çakıllı sahillerde SVMs-L sınıflandırıcısının az farkla da olsa gerisinde kalmıştır.

Çalışma kapsamında en şaşırtıcı sonuçlar Destek Vektör Makineleri sınıflandırıcıları ile elde edilmiştir. Zhang ve diğerleri (2013)'nin belirttiğinin aksine Sigmoid çekirdek fonksiyonun kullanıldığı SVMs sınıflandırıcıları için tüm kıyı tiplerinde hem diğer çekirdek fonksiyonlarına hem de diğer sınıflandırıcı gruplarına kıyasla, en başarısız sonuçlar elde edilmiştir. Diğer çekirdek fonksiyonlar için kıyı tipleri genelinde birbirine yakın ve başarılı sonuçlar elde edilmiştir. Lineer çekirdek fonksiyonun kullandığı SVMs-L sınıflandırıcısı başta kumlu-çakıllı sahiller olmak üzere sahil kıyı tipinde en büyük isabetlilik değerlerini elde etmiştir.

Kolektif Öğrenme sınıflandırıcıları, kıyı tipleri genelinde beklenen isabetliliği gösterememişlerdir. Manaf ve diğerleri (2018)'nin belirttiğinin aksine isabetlilik bakımından SVMs-L, SVMs-P ve SVMs-R sınıflandırıcılarının gerisinde kalmışlardır. Kıyı tiplerine göre farklılık göstermekle birlikte grup içinde yapılan değerlendirmede Uyumlu Arttırma (AdaB) sınıflandırıcısının belirgin bir üstünlüğü bulunmaktadır. Bu sınıflandırıcı özellikle falez kıyı tipinde yüksek isabetlilik göstermiştir.

Çalışma kapsamına uydu görüntülerinde en sık karşılaşılan falez, sahil ve yapay kıyılar ile güçlü Makine Öğrenmesi Sınıflandırıcıları kullanılmıştır. Uydu görüntülerinden kıyı çizgisi çıkartma işleminde, Makine Öğrenmesi Modelleri için kıyı tiplerine bağlı olarak isabetlilikler elde edilmiştir. İşlem gerçekleştirilirken kıyı tipleri, falezlerde gölgeli alanlar içeren görüntüler ve sahillerde ise siltli-killi ve kumlu-çakıllı sahiller ayrıca değerlendirmeye tabi tutulmuştur.

Değerlendirme işleminin objektifliğini arttırmak adına birbirinden bağımsız alanlardan elde edilen veri setleri ile modeller eğitilmiş ve sınanmıştır. Kullanılan spektral bantlar tahminleri güçlendirmek adına çıktı sınıfları ile korelasyonları incelenerek eleme işlemine tabi tutulmuştur ve yeşil ve yakın kızıl ötesi bantları kullanılmıştır. Modellerin en iyi performanslarını elde edebilmeleri için temel parametreleri eğitim veri seti ile bir ayarlama işlemine tabi tutulmuştur. Modellerin tahminleri, kullanıcı denetiminde ve görüntü işleme teknikleri kullanılarak çıkartılan referans kıyı çizgisi üzerinde belirlenen kıyı tiplerine göre kıyaslanmıştır. Elde edilen yeni kanıların yanı sıra önceki çalışmalarda elde edilen kanıların bir kısmının da geçerliliği sorgulanmıştır. Çalışma neticesinde önceki kanıların bazıları desteklendiği gibi, bir kısmı için de aksi yönde bulgulara rastlanmıştır.

Çalışma kapsamına mümkün olan en geniş materyaller dahil edilmeye çalışılsa da, mevcut ve yenilerinin eklendiği bir çok makine öğrenmesi modeli mevcuttur. Ayrıca Dünya üzerinde geniş ve farklı coğrafyaları kaplayan kıyılar spektral ve morfolojik açıdan çok farklı yapılara sahiptir. Gelecek çalışmalarda farklı model ve kıyı tiplerinin eklenmesi ile alanda daha önemli bulguların elde edilebilmesi mümkündür. Bunların yanı sıra çalışma kapsamında kullanılmayan spektral bantların kullanılması da farklı bulguların elde edilmesinde fayda sağlayabilir.

Geleneksel yöntemlere ve görüntü işleme tekniklerine kıyasla, kıyı çizgisi çıkartma işleminde kolaylık ve isabetlilik sağlayan Makine Öğrenmesi Algoritmaları için kıyı tiplerine bağlı olarak isabetlilik değerlendirmesi konusunda fark edilen eksiklik çalışma kapsamında giderilmeye çalışılmıştır. Elde edilen sonuçlar neticesinde, alanda çalışma yapan araştırmacılar ve kıyı çizgisi çıkartma işleminin kullanıldığı bir çok alanda özellikle incelenen alanlardaki baskın kıyı tiplerine bağlı olarak sınıflandırıcı seçiminde bir rehber oluşturulmaya çalışılmıştır. Çıkartılan kıyı çizgilerinde isabetlilik ve güvenilirliğin artırılması ilgili kıyı bölgesinin izlenmesi ve korunmasında önem arz etmektedir. Kıyı çizgisi çıkartma işlemine sağlanan katkıyla beraber, insanlar ve diğer bir çok canlı türü için değerli olan ve risk altındaki kıyı alanlarının korunmasına da katkı sağlanması çalışmanın temel hedefleri arasındadır.

KAYNAKLAR

- Abd Manaf, S., Sulaiman, M., Husin, N., Zainuddin, M., Shafri, H., Shafri, M. (2017). Majority voting of ensemble classifiers to improve shoreline extraction of medium resolution satellite images. *Journal of Theoretical and Applied Information Technology*, 3095, 4394-4405.
- Alesheikh, A.A., Ghorbanali, A., Nouri, N. (2007). Coastline change detection using remote sensing. *International Journal of Environmental Science & Technology*, 4(1), 61-66. doi:10.1007/BF03325962
- Alpaydin, E. (2020). *Introduction to Machine Learning*. Cambridge, Massachusetts, USA: MIT Press.
- Barber, D., ve Bishop, C.M. (1998). Ensemble learning for multi-layer networks. *Advances in Neural Information Processing Systems*, 395–401, Denver, Colorado, USA.
- Bayram, B., Erdem, F., Akpınar, B., Ince, A.K., Bozkurt, S., Catal Reis, H., Seker, D.Z. (2017). The Efficiency of Random Forest Method for Shoreline Extraction from LANDSAT-8 and GOKTURK-2 Imageries. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4(4W4), 141–145, 14-15 January, Safranbolu, Karabuk, Turkey. doi:10.5194/isprs-annals-IV-4-W4-141-2017
- Bishop, C.M. (1996). *Neural networks: A pattern recognition perspective*. Birmingham, UK: Neural Computing Research Group.
- Boak, E.H., Turner, I.L. (2005). Shoreline Definition and Detection: A Review. *Journal of Coastal Research*, 21(4 (214)), 688-703. doi:10.2112/03-0071.1
- Boser, B.E., Guyon, I.M., Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, 144–152, July, 1992, Pittsburg, Pensilvania, USA.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32.
- Brodley, C.E., Utgoff, P.E. (1995). Multivariate decision trees. *Machine learning*, 19(1), 45–77.
- Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., Varoquaux, G. (2013). API design for machine learning software: Experiences from the scikit-learn project. *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, 108–122. 23th-27th September, Prague, Czech Republic.
- Choung, Y.J., 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(1), 1-13.
- Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297. doi:10.1155/2017/8245204
- Crowell, M., Leatherman, S.P., Buckley, M.K. (1991). Historical Shoreline Change: Error Analysis and Mapping Accuracy. *Journal of Coastal Research*, 7(3), 839-852.
- Çelik, O.I., Gazioğlu, C. (2020). Coastline Difference Measurement (CDM) Method. *International Journal of Environment and Geoinformatics*, 7(1), 1–16.
- Dellepiane, S., De Laurentiis, R., Giordano, F. (2004). Coastline extraction from SAR images and a method for the evaluation of the coastline precision. *Pattern Recognition Letters*, 25(13), 1461–1470.


- Dietterich, T.G. (2000). Ensemble methods in machine learning. International workshop on multiple classifier systems, 1–15, 21th-23th June 2000, Cagliari, Italy.
- Dolan, R., Fenster, M.S., Holme, S.J. (1991). Temporal Analysis of Shoreline Recession and Accretion. *Journal of Coastal Research*, 7(3), 723-744.
- Emery, K., Kuhn, G. (1982). Sea cliffs: Their processes, profiles, and classification. *Geological Society of America Bulletin*, 93(7), 644–654.
- Erinç, S. (2010). Jeomorfoloji ii. İstanbul, Türkiye: Der Yayınevi.
- ESA (European Space Agency), (2020). Copernicus Open Access Hub. Erişim Adresi: <https://scihub.copernicus.eu/dhus/#/home> (Erişim Tarihi: 10.06.2020)
- Flemming, B.W. (2002). Geographic distribution of muddy coasts. Healy, T., Wang Y., Healy J.A (Ed.), *Muddy Coasts of the World: Processes, Deposits and Function* (s. 99–201). Amsterdam, Netherlands: Elsevier Science.
- Freund, Y., Schapire, R.E., (1996). Experiments with a new boosting algorithm. *International Conference of Machine Learning*. 148–156, 3th-6th July 1996, Bari, Italy.
- Funahashi, K.I. (1989). On the approximate realization of continuous mappings by neural networks. *Neural networks*, 2(3), 183–192.
- Ge, X., Sun, X., Liu, Z. (2014). Object-oriented coastline classification and extraction from remote sensing imagery. *Remote Sensing of the Environment: 18th National Symposium on Remote Sensing of China*, 91580M, 20-23 October 2012, Wuhan, China
- Gens, R. (2010). Remote sensing of coastlines: Detection, extraction and monitoring. *International Journal of Remote Sensing*, 31(7), 1819-1836. doi:10.1080/01431160902926673
- Geurts, P., Ernst, D., Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3–42. doi:10.1007/s10994-006-6226-1
- Hall, M.A. (1999). Correlation-based Feature Selection for Machine Learning (Yayımlanmamış Doktora Tezi). The University of Waikato, Hamilton, Waikato New Zealand.
- Kalkan, K., Bayram, B., Maktav, D., Sunar, F. (2013). Comparison of support vector machine and object based classification methods for coastline detection. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(7W2), 125–127. doi:10.5194/isprsarchives-XL-7-W2-125-2013
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conferences on Artificial Intelligence*, 14(2), 1137–1145.
- Kuleli, T. (2010). Quantitative analysis of shoreline changes at the Mediterranean Coast in Turkey. *Environmental monitoring and assessment*, 167(1-4), 387–397.
- Ladicky, L., Torr, P.H.S. (2011). Locally Linear Support Vector Machines. *International Conference of Machine Learning*. 985–992. 28th June-2th July, Bellevue, Washington, USA.
- Li, R., Di, K., Ma, R. (2001). A comparative study of shoreline mapping techniques. *GIS for Coastal Zone Management*, 53–60.
- Liu, H., Jezek, K. (2004). Automated extraction of coastline from satellite imagery by integrating Canny edge detection and locally adaptive thresholding methods. *International Journal of Remote Sensing*, 25(5), 937–958.
- Manaf, S.A., Mustapha, N., Sulaiman, M., Husin, N.A., Hamid, M.R.A., (2018). Artificial Neural Networks for Satellite Image Classification of Shoreline Extraction for Land and Water Classes of the North West Coast of Peninsular Malaysia. *Advanced Science Letters*, 24(2), 1382–1387.

- Margineantu, D.D., Dietterich, T.G. (1997). Pruning adaptive boosting. International Conference of Machine Learning, 211–218. 8th-12 July, 1997, Nashville, Tennessee, USA.
- McFeeters, S.K. (2013). Using the normalized difference water index (ndwi) within a geographic information system to detect swimming pools for mosquito abatement: A practical approach. *Remote Sensing*, 5(7), 3544–3561. doi:10.3390/rs5073544
- Mineur, F., Cook, E.J., Minchin, D., Bohn, K., MacLeod, A., Maggs, C.A. (2012). Changing coasts: Marine aliens and artificial structures. *Oceanography and Marine Biology*, 50, 189-234.
- Niedermeier, A., Romaneessen, E., Lehner, S. (2000). Detection of coastlines in SAR images using wavelet methods. *Institute of Electrical and Electronical Engineers Transactions on Geoscience and Remote Sensing*, 38(5), 2270–2281.
- Oshiro, T.M., Perez, P.S., Baranauskas, J.A. (2012). How many trees in a random forest? International workshop on machine learning and data mining in pattern recognition, 154–168. 13th-20th July, 2012, Berlin, Germany.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Pereira, F., Mitchell, T., Botvinick, M. (2009). Machine learning classifiers and fMRI: a tutorial overview. *Neuroimage*, 45(1), 199–209.
- Rokni, K., Ahmad, A., Solaimani, K., Hazini, S. (2015). A new approach for surface water change detection: Integration of pixel level image fusion and image classification techniques. *International Journal of Applied Earth Observation and Geoinformation*, 34, 226-234. doi:10.1016/j.jag.2014.08.014
- Rumelhart, D.E., Hinton, G.E., Williams, R.J. (1985). Learning internal representations by error propagation. Rumelhart, D.E., McClelland, J.L. (Ed.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Cambridge, Massachusetts, USA: MIT Press.
- Ryan, T., Sementilli, P., Yuen, P., Hunt, B. (1991). Extraction of shoreline features by neural nets and image processing. *Photogrammetric Engineering and Remote Sensing*, 57(7), 947–955.
- Scholkopf, B., Smola, A.J. (2001). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. Cambridge, Massachusetts, USA: MIT Press.
- Sekovski, I., Stecchi, F., Mancini, F., 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.
- Sharma, S. (2017). Activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310-316.
- Shenbagaraj, N., Mani, N., Muthukumar, M. (2014). Isodata classification technique to assess the shoreline changes of Kolachel to Kayalpattanam coast. *International Journal of Engineering Research and Technology*, 3(4), 311-314.
- Shi, T., Horvath, S. (2006). Unsupervised learning with random forest predictors. *Journal of Computational and Graphical Statistics*, 15(1), 118–138.
- Su, G., Hu, X., Yan, L., Liu, Y. (2016). Coastline Identification from Remote-sensing Image Using Informative Vector Machine Learning. *International Symposium on Mechanical*


- Engineering and Material Science. 283-287. 17th-19th November, 2016, Jeju Island, South Korea. doi:10.2991/ismems-16.2016.48
- Teodoro, A.C. (2016). Optical satellite remote sensing of the coastal zone environment—An overview. *Environment Applications of Remote Sensing*, 165–196.
- Thia-Eng, C. (1993). Essential elements of integrated coastal zone management. *Ocean & Coastal Management*, 21(1-3), 81–108.
- Verheye, W., Ameryckx, J. (1984). Mineral fractions and classificaton of soil texture. *Pedologie*. 34, 215-225.
- Vitousek, P.M., Mooney, H.A., Lubchenco, J., Melillo, J.M. (1997). Human domination of Earth's ecosystems. *Science*, 277(5325), 494–499.
- Xukai, Z., Qiongqiong, L., Baig, M.H.A. (2012). Automated detection of coastline using Landsat TM based on water index and edge detection methods. *Proceedings of the 2nd International Workshop on Earth Observation and Remote Sensing Applications*.153-156, 8th-11th June, 2012, Shangai, China. doi:10.1109/EORSA.2012.6261155
- Zhang, C., Ma, Y. (2012). *Ensemble machine learning: Methods and applications*. New York, USA: Springer Publishing Company.
- Zhang, H., Jiang, Q., Xu, J. (2013). Coastline Extraction Using Support Vector Machine from Remote Sensing Image. *Journal of multimedia*, 8(2), 175–182.
- Zuo, L., Roelvink, D., Lu, Y., Li, S. (2017). On incipient motion of silt-sand under combined action of waves and currents. *Applied Ocean Research*, 69, 116-125. doi:10.1016/j.apor.2017.10.005

EKLER


EK 1. SVMs Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar




EK 1.1. SVMs-L için Fark Değerleri.



EK 1.2. SVMs-P için Fark Değerleri.




EK 1.3. SVMs-R için Fark Değerleri.




EK 1.4. SVMs-S için Fark Değerleri.


EK 2. MLP Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar




EK 2.1 MLP-I için Fark Değerleri.



EK 2.2. MLP-L için Fark Değerleri.




EK 2.3. MLP-T için Fark Değerleri.




EK 2.4. MLP-R için Fark Değerleri.


EK 3. Kolektif Öğrenme Sınıflandırıcıları için Referans Kıyı Çizgisi Boyunca Farklar




EK 3.1. RT için Fark Değerleri.



EK 3.2. ET için Fark Değerleri.



EK 3.3. GB için Fark Değerleri.



EK 3.4. AdaB için Fark Değerleri.

ÖZGEÇMİŞ

Doğum tarihi :
Doğum yeri :
Lise : (2005-2009), Hüseyin Bürge Anadolu Lisesi
Lisans : (2010-2016), Yıldız Teknik Üniversitesi/İnşaat Mühendisliği
Çalıştığı Kurum : (2017-2019), Denar Deniz Araştırmaları A.Ş.
ORCID Kimliği : 0000-0002-3788-9988
Bilimsel Etkinlikleri : Dergide Makale:
Çelik, O.I., Gazioğlu, C. (2020). Coastline Difference Measurement (CDM) Method. International Journal of Environment and Geoinformatics, 7(1), 1–16. doi: 10.30897/ijegeo.706792





T.C.
İSTANBUL ÜNİVERSİTESİ
DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ
TEZ BENZERLİK RAPORU UYGUNLUK FORMU



ÖĞRENCİNİN ADI SOYADI : Osman İsa Çelik
ÖĞRENCİ NO : 3001170023
ÖĞRETİM YILI : 2019 - 2020 , Bahar
ANABİLİM DALI / BİLİM DALI : Denizel Ç. / Kıyı Müh.
PROGRAM TÜRÜ : YÜKSEK LİSANS ☒ DOKTORA ☐
TEZ DANIŞMANI ÜNVANI ADI SOYADI : : Prof. Dr. Cem Gazioğlu
II. TEZ DANIŞMANI ÜNVAN ADI SOYADI : UYDU GÖRÜNTÜLERİNDEN KIYI ÇİZGİSİ TESPİTİNDE
TEZ BAŞLIĞI : MAKİNE ÖĞRENMESİ ALGORİTMALARININ
PERFORMANSLARININ DENEYSEL OLARAK
KARŞILAŞTIRILMASI

DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE,

Yukarıda başlığı verilen tez çalışmamın Kapak sayfası, Türkçe ve İngilizce özet, giriş ve amaç, genel bilgiler, materyal-
metot, bulgular, tartışma, sonuç ve kaynaklar bölümlerinden oluşan toplam. 27 . sayfalık kısmına ilişkin, 30/06/2020 tarihinde
Deniz Bilimleri ve İşletmeciliği Enstitüsünün kullandığı TURNİTİN programı ile, *Lisansüstü Tezlere ait Benzerlik
Raporlarının Alınması ve Kullanılmasına İlişkin Uygulama Esaslarının* 5inci madde ikinci fıkrasında belirtilen filtrelemeler
uygulanarak alınmış nihai rapora göre benzerlik oranı % 3 'dir.

Tezimin benzerlik oranı, 06/122017 tarih ve 20 sayılı Deniz Bilimleri ve İşletmeciliği Enstitüsü Yönetim Kurul
Kararıyla Tezin intihal kapsamı dışında değerlendirilmesi için kabul edilmiş olan üst sınır benzerlik oranını aşmamaktadır.

İntihal programı ile raporlanan Tezime ait Benzerlik oranım Üst sınır benzerlik oranının altında olsa dahi aksinin tespit
edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu beyan ederim.

Gereğini arz ederim.

İmza
Öğrenci Ad-Soyadı
Tarih: 30 / 06 / 2020

Osman İsa ÇELİK

EK: TURNİTİN Benzerlik Nihai Raporu ilk sayfa çıktısı

DANIŞMAN ONAYI
UYGUNDUR / UYGUN DEĞİLDİR

Prof. Dr. Cem GAZİOĞLU

İSTANBUL ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM VE ÖĞRETİM YÖNETMELİĞİ (08.09.2016/29825)

(Yüksek Lisans) MADDE 36 – (2) Tezle ilgili benzerlik ön incelemesi, danışmanın bilgisi dahilinde öğrenci ile birlikte Üniversitenin kabul ettiği yazılım programı kullanılarak yapılır. Enstitü, söz konusu teze ilişkin intihal yazılım programı nihaî raporunu alarak danışmana ve jüri üyelerine gönderir. Rapordaki verilerde veya sınav jüri üyesi/üyelerinin somut kanıtlarla belgeledikleri verilere göre gerçek bir intihalin tespiti halinde; tez, gerekçesi ile birlikte, karar verilmek üzere enstitü yönetim kuruluna gönderilir.

(Doktora) MADDE 50 – (4) Öğrenci, doktora tezinin savunmasından önce tezini, düzeltme verilen tezlerde ise düzeltilmiş tezini danışmanına sunar. Tezle ilgili benzerlik ön incelemesi, danışmanın bilgisi dahilinde öğrenci ile birlikte Üniversitenin kabul ettiği yazılım programı kullanılarak yapılır. Enstitü, söz konusu teze ilişkin intihal yazılım programı nihaî raporunu alarak danışmana ve jüri üyelerine gönderir. Rapordaki verilerde veya sınav jüri üyesi/üyelerinin somut kanıtlarla belgeledikleri verilere göre gerçek bir intihalin tespiti halinde; tez, gerekçesi ile birlikte, karar verilmek üzere enstitü yönetim kuruluna gönderilir

Uydu Görüntülerinden Kıyı Çizgisi Tespitinde Makine Öğrenmesi Algoritmalarının Performanslarının Deneysel Olarak Karşılaştırılması

Yazar Osman İsa Çelik

Gönderim Tarihi: 30-Haz-2020 09:30AM (UTC+0300)

Gönderim Numarası: 1351682745

Dosya adı: osman_isa_elik-yl.docx (644.09K)

Kelime sayısı: 7893

Karakter sayısı: 54402

Uydu Görüntülerinden Kıyı Çizgisi Tespitinde Makine Öğrenmesi Algoritmalarının Performanslarının Deneysel Olarak Karşılaştırılması

ORIJINALLIK RAPORU

%3

BENZERLİK ENDEKSİ

%2

İNTERNET
KAYNAKLARI

%1

YAYINLAR

%2

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1

Submitted to University College London

Öğrenci Ödevi

<%1

2

tufuab2017.aku.edu.tr

İnternet Kaynağı

<%1

3

Submitted to Siksha 'O' Anusandhan University

Öğrenci Ödevi

<%1

4

Submitted to Istanbul Gelisim University

Öğrenci Ödevi

<%1

5

Submitted to Tobb University of Economics & Technology

Öğrenci Ödevi

<%1

6

www.progmat.hu

İnternet Kaynağı

<%1

7

Submitted to Mimar Sinan Guzel Sanatlar University

Öğrenci Ödevi

<%1

8	www.bilmat.org İnternet Kaynağı	<% 1
9	docplayer.biz.tr İnternet Kaynağı	<% 1
10	mtegm.meb.gov.tr İnternet Kaynağı	<% 1
11	Submitted to Recep Tayyip Erdogan University Öğrenci Ödevi	<% 1
12	YILDIZ, Hülya, BOZKURT, Yeşim Akaydın, KOZLU, Tolunay and KOÇ, Ahmet. "Ratlarda prenatal, postnatal ve erişkin dönemlerde glandula submandibularis'in gelişimi üzerinde ışık mikroskopik çalışmalar", Atatürk Üniversitesi Veteriner Fakültesi, 2010. Yayın	<% 1
13	worldwidescience.org İnternet Kaynağı	<% 1
14	www.yumpu.com İnternet Kaynağı	<% 1
15	Submitted to Universidad Carlos III de Madrid Öğrenci Ödevi	<% 1
16	web.itu.edu.tr İnternet Kaynağı	<% 1

Alıntıları çıkart

üzerinde

Eşleşmeleri çıkar

< 5 words

Bibliyografyayı Çıkart

üzerinde

