T.C.
İSTANBUL ÜNİVERSİTESİ
DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ

DOKTORA TEZİ

M. Sc. Osman İsa ÇELİK
Denizel Çevre Ana Bilim Dalı

Danışman
Prof. Dr. Cem GAZİOĞLU

MAYIS, 2025

T.C.

İSTANBUL ÜNİVERSİTESİ

DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ

OSMAN İSA ÇELİK tarafından hazırlanmış ve sunulmuş "DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ" başlıklı tez DENİZEL ÇEVRE Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Tez Danışmanı
Prof. Dr. Cem GAZİOĞLU (D)

Jüri Üyesi
Prof. Dr. Gürcan BÜYÜKSALİH

Jüri Üyesi
Prof. Dr. Dursun Zafer ŞEKER

Jüri Üyesi
Doç. Dr. Tolga BAKIRMAN

Jüri Üyesi
Dr. Öğr. Üyesi Başak SAVUN

Tez Savunma Tarihi: 26.05.2025

ETİK BEYAN

İstanbul Üniversitesi Deniz Bilimleri ve İşletmeciliği Enstitüsü Tez Yazım Kılavuzu kurallarına uygun olarak hazırladığım "DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ" başlıklı DOKTORA 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 yanlı 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.

22.05.2025

Osman İsa Çelik

İmza

“Değerli Eşim Selin’e”

ÖNSÖZ

Bu doktora tezi, kıyı alanlarının spektral ve dokusal değişkenlere dayalı olarak derin öğrenme yöntemleriyle sınıflandırılmasını incelemektedir. Kıyı şeritlerinin biyoçeşitlilik ve ekonomik değerleri, iklim değişikliği ve insan faaliyetlerinin tehditleri altında korunması gereken kritik ekosistemler olduğunu ortaya koymaktadır. Bu çalışma, uzaktan algılama ve derin öğrenme teknolojilerini birleştirerek, kıyıların etkin izlenmesi ve sürdürülebilir yönetimi için yenilikçi bir yaklaşım sunmayı amaçlamaktadır. Tez, farklı kıyı tiplerinin otomatik sınıflandırmasını sağlayarak, erozyon kontrolü, habitat koruma ve kıyı yönetimi politikalarına katkıda bulunmayı hedeflemektedir.

Doktora 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 iv
ABSTRACT v
TABLO LİSTESİ vi
ŞEKİL LİSTESİ vii
SİMGE LİSTESİ viii
KISALTMA LİSTESİ ix
EKLER LİSTESİ x
1. GİRİŞ 1
1.1. Kıyı Şeritlerinin Biyoçeşitlilik ve Ekonomik Önemi 1
1.2. Kıyı Bölgelerindeki Tehditler ve İzleme Gerekliliği 1
1.3. Geleneksel Yöntemlerin Sınırlılıkları ve Uzaktan Algılama Teknolojileri 2
1.4. Derin Öğrenmenin Kıyı Uygulamalarındaki Potansiyeli 2
1.5. Derin Öğrenme Uygulamalarındaki Araştırma Boşlukları 3
1.6. Tezin Amaçları ve Katkıları 3
2. MATERYAL VE METOT 5
2.1. Uydu Görüntüsü 5
2.2. Kıyı Tipleri 6
2.2.1. Kumlu kıyılar 7
2.2.2. Kayalık kıyılar 8
2.2.3. Haliç tipi kıyılar 9
2.2.4. Antropojenik kıyılar 9
2.2.5. Mercan resifleri 10
2.2.6. Volkanik kıyılar 11
2.2.7. Buzul kıyıları 12
2.3. Çalışma Alanı ve Örnekleme Stratejisi 13
2.4. Veri Temini ve Ön İşleme 15
2.5. Veri Setinin Hazırlanması 16
2.6. Modifiye Edilen VGG16 Mimarisi 18
2.7. Transfer Öğrenimi 20
2.8. Derin Öğrenme Modeli için Eğitim ve Doğrulama Konfigürasyonu 21
2.9. Spektral Analizler 22
2.10. Dokusal Analizler 22
2.10.1. Kontrast (Contrast) 23
2.10.2. Benzeşmezlik (Dissimilarity) 23
2.10.3. Homojenlik (Homogeneity) 23
2.10.4. Enerji (Energy) 24
2.10.5. Korelasyon (Correlation) 24
2.11. Model Performansı Değerlendirme Yöntemleri 24
2.11.1. Genel doğruluk ve eğitim/doğrulama değerleri 25
2.11.2. Karışıklık matrisi (confusion matrix) 25
2.11.3. Alıcı işletim karakteristiği (roc) eğrisi 25

3. BULGULAR....26
3.1. Spektral Analiz Bulguları....26
3.1.1. Mavi bant yansıma değerleri....26
3.1.2. Yeşil bant yansıma değerleri....28
3.1.3. Kırmızı bant yansıma değerleri....29
3.1.4. Yakın kızılötesi bant reflektans değerleri....31
3.2. Dokusal Analiz Bulguları....32
3.2.1. Kontrast ölçütü....32
3.2.2. Benzeşmezlik ölçütü....34
3.2.3. Homojenlik ölçütü....35
3.2.4. Enerji ölçütü....36
3.2.5. Korelasyon ölçütü....38
3.3. Model Performansı Bulguları....39
3.3.1. Genel doğruluk değerleri....39
3.3.2. ROC eğrileri....40
3.3.3. Karışıklık matrisleri....47
4. TARTIŞMA VE SONUÇ....51
4.1. Spektral Özelliklerin Rolü ve NIR Bandının Önemi....51
4.2. Dokusal Özelliklerin Rolü....52
4.3. Sınıflandırma Performansı....52
4.4. Spektral ve Dokusal Özelliklerin Sınıflandırmaya Etkisi....52
4.5. Transfer Öğreniminin Katkısı....53
4.6. Bulguların Literatürle Karşılaştırması....53
4.7. Sınırlamalar ve Gelecek Çalışmalar....54
4.8. Sonuçlar....54
EKLER....63
EK 1. Model Eğitim ve Doğrulama Grafikleri....63
ÖZGEÇMİŞ....67

ÖZET

DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ

Osman İsa ÇELİK

Kıyı alanlarının biyoçeşitlilik ve ekonomik değerine rağmen iklim değişikliği ve insan faaliyetleri nedeniyle karşılaştığı tehditler, etkin izleme yöntemlerini zorunlu kılmaktadır. Bu çalışma, geleneksel yaklaşımların sınırlılıklarını aşmak için uzaktan algılama ve derin öğrenme teknolojilerini kullanarak kıyı şeritlerinin spektral ve dokusal değişkenlere dayalı sınıflandırılmasını araştırmaktadır. Google Earth Engine platformunda Sentinel-2 uydu görüntüleri kullanılarak, transfer öğrenimi destekli VGG16 modeliyle yedi kıyı sınıfı (kumlu, kayalık, haliç tipi, antropojenik, mercan resifleri, volkanik, buzul) sınıflandırılmıştır. Spektral analizler, yakın kızılötesi bandının bitki örtüsü yoğun sınıfları ayırmadaki önemini gösterirken, dokusal analizler antropojenik ve haliç tipi kıyıların heterojen yapısının sınıflandırma başarısına olumlu et kisini ortaya koymuştur. Transfer öğrenimi, modelin doğruluğunu önemli ölçüde iyileştirmiştir; yakın kızılötesi-yeşil-mavi bant kombinasyonunda doğruluk oranı %74,69'dan %96,97'ye yükselmiştir. Ancak, kayalık, buzul ve volkanik kıyılar gibi spektral ve dokusal örtüşme gösteren sınıfların ayrıştırılmasında zorluklar yaşanmıştır. Bu tez, multispektral verilerle dokusal özelliklerin birleştirilmesiyle erişilebilir ve genellenebilir kıyı sınıflandırma çözümleri sunarak literatüre katkıda bulunmaktadır. Elde edilen bulgular, kıyı yönetimi, erozyon kontrolü ve habitat koruma için sürdürülebilir politikaların geliştirilmesine destek olmaktadır. Gelecekte farklı derin öğrenme mimarileriyle genelleştirme güçlendirilebilir.

Anahtar Kelimeler: Derin Öğrenme, kıyı sınıflandırması, spektral analiz, dokusal özellikler, uzaktan algılama

ABSTRACT

DETERMINATION OF COASTAL AREAS BASED ON SPECTRAL AND TEXTURAL VARIABLES USING DEEP LEARNING METHODS

Osman İsa ÇELİK

Coastal areas, despite their biodiversity and economic value, face significant threats from climate change and human activities, necessitating effective monitoring methods. This study investigates the classification of coastal areas based on spectral and textural features using remote sensing and deep learning technologies, aiming to overcome the limitations of traditional approaches. Employing Sentinel-2 satellite imagery on the Google Earth Engine platform, seven coastal classes (sandy, rocky, estuarine, anthropogenic, coral reefs, volcanic, glacial) were classified using a VGG16 model enhanced by transfer learning. Spectral analyses revealed the near-infrared band's crucial role in differentiating vegetation-dense classes, while textural analyses confirmed the heterogeneous structure of anthropogenic and estuarine coasts positively impacted classification success. Transfer learning significantly improved model accuracy; the near-infrared-green-blue band combination increased accuracy from 74.69% to 96.97%. However, challenges arose in distinguishing classes with spectral and textural overlaps, such as rocky, glacial, and volcanic coastlines. This thesis contributes to the literature by offering accessible and generalizable coastal classification solutions through the integration of multispectral data and textural features. The findings support the development of sustainable policies for coastal management, erosion control, and habitat protection. Future work can strengthen generalization using different deep learning architectures.

Keywords: Deep learning, coastal classification, spectral-textural features, Sentinel-2, remote sensing

TABLO LİSTESİ

Sayfa

Tablo 1. Çalışmada Kullanılan Sentinel-2 Bantlarının Özellikleri.....6
Tablo 2. Mavi bant için kıyı sınıflarına ait tanımlayıcı istatistikler.....27
Tablo 3. Yeşil bant için kıyı sınıflarına ait tanımlayıcı istatistikler.....28
Tablo 4. Kırmızı bant için kıyı sınıflarına ait tanımlayıcı istatistikler.....30
Tablo 5. Yakın kızılötesi bant için kıyı sınıflarına ait tanımlayıcı istatistikler.....31
Tablo 6. Kontrast ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler. 33
Tablo 7. Benzeşmezlik ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler. 34
Tablo 8. Homojenlik ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler. 35
Tablo 9. Enerji ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler. 37
Tablo 10. Korelasyon ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler. 38

ŞEKİL LİSTESİ

Sayfa

Şekil 1. Kumlu kıyılara ait örnek uydu görüntüleri. 7
Şekil 2. Kayalık kıyılara ait örnek uydu görüntüleri. 8
Şekil 3. Haliç tipi kıyılara ait örnek uydu görüntüleri. 9
Şekil 4. Antropojenik kıyılara ait örnek uydu görüntüleri. 10
Şekil 5. Mercan resiflerine ait örnek uydu görüntüleri. 11
Şekil 6. Volkanik kıyılara ait örnek uydu görüntüleri. 12
Şekil 7. Buzul kıyılarına ait örnek uydu görüntüleri 13
Şekil 8. Örnekleme bölgelerinin Dünya genelinde dağılımı. 14
Şekil 9. Alt örnekleme işlemi. 15
Şekil 10. Veri temini ve ön işleme süreçleri için metodolojik akış. 16
Şekil 11. Veri setinden rastgele seçilen örnekler. 17
Şekil 12. VGG16 orijinal mimarisi (üst panel) ve bu çalışmada yedi kıyı sınıfını sınıflandırmak üzere uygulanan modifikasyonlar (alt panel). 19
Şekil 13. Mavi bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği). 27
Şekil 14. Yeşil bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği). 29
Şekil 15. Kırmızı bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği). 30
Şekil 16. Yakın kızılötesi bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği). 32
Şekil 17. Kıyı sınıfları için hesaplanan kontrast değerleri (kutu grafiği). 33
Şekil 18. Kıyı sınıfları için hesaplanan benzeşmezlik değerleri (kutu grafiği). 35
Şekil 19. Kıyı sınıfları için hesaplanan homojenlik değerleri (kutu grafiği). 36
Şekil 20. Kıyı sınıfları için hesaplanan enerji değerleri (kutu grafiği). 37
Şekil 21. Kıyı sınıfları için hesaplanan korelasyon değerleri (kutu grafiği). 39
Şekil 22. Denemeler neticesinde elde edilen genel isabetlilik yüzdeleri. 40
Şekil 23. Kumlu kıyılar için ROC eğrileri. 41
Şekil 24. Antropojenik kıyılar için ROC eğrileri. 42
Şekil 25. Kayalık kıyılar için ROC eğrileri. 43
Şekil 26. Haliç tipi kıyılar için ROC eğrileri. 44
Şekil 27. Volkanik kıyılar için ROC eğrileri. 45
Şekil 28. Mercan resifleri için ROC eğrileri. 46
Şekil 29. Buzul kıyıları için ROC eğrileri. 47
Şekil 30. Tüm bant kombinasyonlarına göre karışıklık matrisleri. 48
Şekil 31. NIR-G-B bant kombinasyonu için karışıklık matrisleri.. 48
Şekil 32. NIR-R-B bant kombinasyonu için karışıklık matrisleri. 49
Şekil 33. NIR-R-G kombinasyonu için karışıklık matrisleri. 50
Şekil 34. R-G-B kombinasyonu için karışıklık matrisleri. 50
Şekil 35. İsabetlilik ve kayıp değerleri (R-G-B veri seti). 63
Şekil 36. İsabetlilik ve kayıp değerleri (NIR-G-B veri seti). 64
Şekil 38. İsabetlilik ve kayıp değerleri (NIR-R-G veri seti). 65
Şekil 39. İsabetlilik ve kayıp değerleri (NIR-R-B veri seti). 66

SİMGE LİSTESİ

B2	: 2 Numaralı Bant (Sentinel-2 Mavi Bant)
B3	: 3 Numaralı Bant (Sentinel-2 Yeşil Bant)
B4	: 4 Numaralı Bant (Sentinel-2 Kırmızı Bant)
B8	: 8 Numaralı Bant (Sentinel-2 Yakın Kızılötesi Bant)
°	: Derece Sembolü
i	: Gri seviye eş-oluşum matrisinde satır indisi
j	: Gri seviye eş-oluşum matrisinde sütun indisi
p(i,j)	: Normalize edilmiş gri seviye eş-oluşum matrisi elemanı
μi	: Satır gri seviye ortalaması
σi	: Satır gri seviye standart sapması
μj	: Sütun gri seviye ortalaması
σj	: Sütun gri seviye standart sapması
∑	: Toplam Sembolü

KISALTMA LİSTESİ

AUC	: Area Under the Curve (Eğri Altındaki Alan)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
DN	: Digital Number (Dijital Numara)
ESA	: European Space Agency (Avrupa Uzay Ajansı)
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
GEE	: Google Earth Engine
GLCM	: Gray-Level Co-Occurrence Matrix (Gri Seviye Eş-Oluşum Matrisi)
İHA	: İnsansız Hava Aracı
LST	: Land Surface Temperature (Yüzey Sıcaklığı)
LiDAR	: Light Detection and Ranging (Işık Tespiti ve Mesafe Ölçümü)
MSI	: Multispectral Instrument (Çok Bantlı Enstrüman)
NIR	: Near-Infrared (Yakın Kızılötesi)
NDVI	: Normalized Difference Vegetation Index (Normalize Fark Bitki Örtüsü İndeksi)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
RMSprop	: Root Mean Square Propagation (Karekök Ortalama Yayılımı)
SWIR	: Short-Wave Infrared (Kısa Dalga Kızılötesi)
TPR	: True Positive Rate (Doğru Pozitif Oranı)
VNIR	: Visible and Near-Infrared (Görünür ve Yakın Kızılötesi)

EKLER LİSTESİ

Sayfa

EK 1. Model Eğitim ve Doğrulama Grafikleri 63

1. GİRİŞ

1.1. Kıyı Şeritlerinin Biyoçeşitlilik ve Ekonomik Önemi

Kıyı şeritlerimiz, zengin bir biyoçeşitliliğe ev sahipliği yapan denizel ekosistemlerle kaplıdır. Gelişen mercan resifleri, geniş deniz çayırı yatakları ve hayati öneme sahip mangrov ormanları bu ekosistemlerin önemli bileşenleridir (Kenchington, 2009). Dünya Bankası (World Bank, 2016) verilerine göre, bu bölgeler yalnızca yaşamın kaynağı olmakla kalmayıp, kıyı bölgelerinde yaşayan dünya nüfusunun yarısından fazlasını destekleyen kritik ekonomik kaynaklardır. Verimli balıkçılıktan tarım arazilerine kadar kıyı ekosistemleri, turizm, rekreasyon ve denizcilik gibi birçok sektörün temelini oluşturan çeşitli kaynaklar sunmaktadır (Kelleher, 1999). Ancak bu dinamik bölgeler, artan insan faaliyetleri ve iklim değişikliğinin etkileriyle ciddi tehditler altındadır.

1.2. Kıyı Bölgelerindeki Tehditler ve İzleme Gerekliliği

Kıyı bölgelerindeki değişimlerin ekosistemler ve insan yaşamı üzerindeki etkisi, bu alanların detaylı bir şekilde izlenmesini ve yönetilmesini zorunlu kılmaktadır. İklim değişikliği, yükselen deniz seviyeleriyle alçak kıyı bölgelerini sular altında bırakmakta, kıyı şeritlerini aşındırmakta ve toplulukları yerinden etmektedir (Williams, 2013; Zitouni ve diğerleri, 2025). Ayrıca, insan faaliyetleri bu tehditleri daha da artırmaktadır; gübreler ve pestisitlerle yüklü tarımsal akış kıyı sularını kirletirken, dip trolleri gibi yıkıcı balıkçılık uygulamaları hassas yaşam alanlarını önemli ölçüde tahrip etmektedir (Mbow ve diğerleri, 2017). Son çalışmalar, iklim ve arazi örtüsü arasındaki ilişkiyi inceleyerek bu değişimlerin boyutlarını anlamaya odaklanmıştır. Örneğin, İtalya üzerine yapılan bir araştırmada, bitki örtüsü ve iklim arasındaki bağlantıyı analiz etmek için eşevrelilik ve faz gecikmesi yöntemleri kullanılmış, normalize edilmiş fark bitki örtüsü indeksi (NDVI) ve yüzey sıcaklığı (LST) yıllık döngülerinin çoğu ekolojik bölgede eş fazda olduğu ve bu faktörler arasında güçlü bir ilişki bulunduğu gösterilmiştir (Ghaderpour ve diğerleri, 2023). Benzer şekilde, Güney Amerika'da gerçekleştirilen bir çalışma, bitki örtüsü ve arazi örtüsü üzerine yeni ve yüksek doğruluklu bir

veri seti sunarak, kıyı ortamlarında arazi örtüsü ve iklim arasındaki karmaşık etkileşimlerin önemini vurgulamıştır (Alves ve diğerleri, 2024). Bu bulgular, kıyı dinamiklerinin etkin yönetimi ve korunması için daha kapsamlı bir anlayış gerektirdiğini ortaya koymaktadır (McCarthy ve diğerleri, 2017).

1.3. Geleneksel Yöntemlerin Sınırlılıkları ve Uzaktan Algılama Teknolojileri

Geleneksel kıyı izleme yöntemleri, genellikle zaman alıcı ve öznel olup geniş ölçekli uygulamalarda etkinlikleri sınırlı kalmaktadır (Bio ve diğerleri, 2015; Ventura ve diğerleri, 2018). Ancak teknolojideki ilerlemeler, bu karmaşık ortamları incelemek ve yönetmek için güçlü araçlar sunmaktadır (Noh ve diğerleri, 2024). Özellikle uzaktan algılama teknolojileri, bilim insanlarına sinoptik bir bakış açısı sağlayarak kıyı değişikliklerini geniş bir ölçekte izleme imkanı sunmaktadır (Vitousek ve diğerleri, 2023). Uydular, yüksek çözünürlüklü verilerle Dünya yüzeyinin geniş alanlarını yakalayarak kıyı şeridi erozyonu ve arazi örtüsü değişikliklerini izlemede önemli bir rol oynamaktadır (Esmail ve diğerleri, 2019; Teodoro, 2016). Ancak, bu büyük veri kümelerinden anlamlı bilgiler elde etmek için gelişmiş analitik tekniklere ihtiyaç duyulmaktadır.

1.4. Derin Öğrenmenin Kıyı Uygulamalarındaki Potansiyeli

Derin öğrenme, yapay zekanın hızla gelişen bir alt alanı olarak otomatik ve verimli kıyı izleme için güçlü bir araçtır (Lv ve diğerleri, 2024). Çok katmanlı sinir ağları, örneğin Evrişimsel Sinir Ağı (CNN), kullanarak karmaşık örüntüleri öğrenen ve sınıflandırma görevlerini gerçekleştiren bu yöntem, büyük veri kümelerini anlamlandırmada etkilidir. Birçok çalışma, derin öğrenmenin kıyı uygulamalarındaki potansiyelini ortaya koymuştur. Örneğin, Dang (2024), uydu görüntülerinde kıyı şeridi tespiti için derin öğrenme yöntemlerini kullanmış ve yüksek doğruluk elde etmiştir. Dang ve diğerleri (2020), Vietnam'daki arazi örtüsünü CNN tabanlı bir modelle %89'un üzerinde bir doğrulukla sınıflandırmıştır. Gonzalez-Perez ve diğerleri (2022), İnsansız Hava Araçları'ndan (İHA) elde edilen verilerle CNN ve makine öğrenmesi kombinasyonunu kullanarak ABD'nin güneydoğusundaki sulak alan bitki örtüsünü %85 doğrulukla sınıflandırmıştır. Jamali ve Mahdianpari (2022), CNN'ler ve Transformer mimarisini birleştirerek ABD'nin doğusundaki kıyı sulak alanlarını %92,30 doğrulukla sınıflandırmıştır. Ayrıca, Bishop-Taylor ve diğerleri (2021), multispektral görüntülerde NIR bandının bitki örtüsü ve su ayrımında önemli olduğunu belirtmiş; Pardo-Pascual ve diğerleri (2012), spektral özelliklerin kıyı çizgisi tespitindeki değerini vurgulamıştır. Hu ve diğerleri

(2019), hiperspektral uydu ve saha verilerini CNN ile birleştirerek kıyı sulak alanlarını %85 civarında bir doğrulukla sınıflandırmıştır. Derin öğrenme modelleri, spektral ve dokusal örüntüleri otomatik olarak öğrenerek karmaşık sınıflandırma görevlerini başarıyla yerine getirebilmektedir.

1.5. Derin Öğrenme Uygulamalarındaki Araştırma Boşlukları

Derin öğrenme, kıyı sınıflandırmasında önemli bir potansiyele sahip olmasına rağmen, bazı kritik boşluklar tam potansiyelini sınırlamaktadır. Derin öğrenme modelleri, küresel kıyı uygulamaları için genellikle yetersiz olan büyük miktarda eğitim verisine ihtiyaç duyar. Mevcut çalışmalar çoğunlukla bölgesel ölçeklere ve belirli arazi örtülerine odaklanır; bu da modellerin genellenebilirliğini kısıtlar. Örneğin, Vietnam'daki (Dang ve diğerleri, 2020) veya belirli sulak alanlara yönelik (Gonzalez-Perez ve diğerleri, 2022; Jamali ve Mahdianpari, 2022) çalışmalar, farklı coğrafi bölgelerde aynı performansı göstermeyebilir. Ayrıca, Bishop-Taylor ve diğerleri (2021) ile Pardo-Pascual ve diğerleri (2012), spektral özelliklerin genel etkisini incelemiş, ancak belirli kıyı tiplerine odaklanmamıştır. Bu boşluklar, küresel ölçekte temsil kabiliyeti yüksek veri setlerinin eksikliğini ve ticari olmayan yüksek çözünürlüklü uydu görüntülerinin potansiyelinin yeterince değerlendirilmediğini ortaya koymaktadır. Bu tez, çeşitli kıyı tiplerini kapsayan geniş bir veri seti ve multispektral verilerle dokusal özelliklerin birleşimiyle bu boşlukları gidermeyi amaçlar. Bu yaklaşım, heterojen kıyı sınıflarını daha iyi ayırt ederek genellenebilirliği artırabilir ve erişilebilir veri kaynaklarıyla düşük maliyetli çözümler sunabilir.

1.6. Tezin Amaçları ve Katkıları

Bu tez, geniş kıyı şeritlerini verimli ve doğru bir şekilde sınıflandırmak için otomatik yöntemler geliştirme ihtiyacını ele almaktadır. Çalışmanın temel amaçları şunlardır: Google Earth Engine (GEE) platformunda VGG16 derin öğrenme modelini kullanarak veri işlemek ve sınıflandırma yapmak, Sentinel-2 verilerinden farklı bant kombinasyonlarıyla VGG16'nın performansını değerlendirmek ve öğrenme transferinin sınıflandırma doğruluğuna etkisini incelemek. Bu yaklaşım, derin öğrenme modellerinin otomatik kıyı sınıflandırmasındaki potansiyelini ve sınırlılıklarını ortaya koymayı hedefler.

Çalışma, literatürdeki temel boşlukları doldurmayı amaçlamaktadır. Küresel ölçekte temsil kabiliyeti yüksek bir veri seti kullanarak önceki çalışmaların bölgesel sınırlılıklarını aşmayı ve farklı coğrafi bölgelerdeki kıyı tiplerini kapsayan genellenebilir modeller geliştirmeyi hedeflemektedir. Haliç Tipi, Kayalık, Antropojenik, Buzul ve Volkanik Kıyılar

gibi çeşitli kıyı sınıflarını birleştirerek daha geniş bir sınıflandırma yelpazesi sunmakta ve literatürdeki belirli kıyı tiplerine odaklanma eksikliğini gidermeyi amaçlamaktadır. Ayrıca, multispektral verilerle dokusal özellikleri birleştirerek heterojen sınıfların ayrıştırılmasında yenilikçi bir perspektif sunarak, hiperspektral veri veya ek veri kaynaklarına bağımlılığı azaltarak daha erişilebilir ve düşük maliyetli çözümler önermektedir.

2. MATERYAL VE METOT

2.1. Uydu Görüntüsü

Bu çalışmada, ortorektifiye edilmiş ve atmosferik olarak düzeltilmiş Level-2A Sentinel-2 uydu görüntüleri kullanılarak analizler gerçekleştirilmiştir. Avrupa Uzay Ajansı (ESA) Copernicus Programı tarafından sağlanan Sentinel-2 görüntüleri, kıyı ortamlarının incelenmesi ve izlenmesi de dahil olmak üzere çok çeşitli Dünya gözlem uygulamaları için önemli bir veri kaynağıdır (Gascon ve diğerleri, 2014). Sentinel-2 misyonu, aynı yörüngede ancak 180° faz farkıyla hareket eden iki kutupsal yörüngeli uyduyu (Sentinel-2A ve Sentinel-2B) teşkil eden bir bütündür. Bu yapılandırma, Ekvator'da 5 günlük yüksek bir tekrar sıklığı sağlayarak, kıyı bölgelerinde meydana gelen dinamik süreçlerin sık sık izlenmesine olanak tanır. 290 km'lik geniş şerit genişliği, 56° Güney ve 82,8° Kuzey enlemleri arasında, kıyıdan 20 km'ye kadar olan iç ve kıyı suları da dahil olmak üzere tüm kıtasal kara yüzeylerinin sistematik olarak kapsanmasını sağlar (Spoto ve diğerleri, 2012).

Her Sentinel-2 uydusu, elektromanyetik spektrumun görünür ve yakın kızılötesi (VNIR) ile kısa dalga kızılötesi (SWIR) bölümleri arasında değişen 13 spektral bantta Dünya'nın yansıyan ışımasını örnekleyen bir Çok Spektralli Enstrüman (MSI) taşır. Bu bantlar farklı uzamsal çözünürlüklere sahiptir: dört bant (Kırmızı, Yeşil, Mavi ve Yakın Kızılötesi dahil) 10 metrelik, altı bant 20 metrelik ve üç bant 60 metrelik çözünürlüktedir. Bu çalışma, yüksek uzamsal çözünürlükleri ve kıyı özelliklerine dair detaylı bilgi yakalama yetenekleri nedeniyle Tablo 1'de spektral ve uzamsal özellikleri verilen dört VNIR bandına (B2 - Mavi, B3 - Yeşil, B4 - Kırmızı ve B8 - Yakın Kızılötesi (NIR)) odaklanmaktadır (Drusch ve diğerleri, 2012; Gascon ve diğerleri, 2014).

Tablo 1. Çalışmada kullanılan Sentinel-2 bantlarının özellikleri

Bant Adı	Dalga Boyu Aralığı (nm)	Merkezi Dalga Boyu (nm)	Uzamsal Çözünürlük (m)
Mavi (B2)	458-523	490	10
Yeşil (B3)	543-578	560	
Kırmızı (B4)	650-680	665	
Yakın Kızılötesi (B8)	785-899	842	

2.2. Kıyı Tipleri

Dünyanın çeşitli kıyı şeritlerini sınıflandırmak, bu dinamik ortamları şekillendiren çok sayıda süreci ve bunların çeşitli bakış açılarından incelenebilmesini yansıtan karmaşık bir çabadır (Finkl, 2004). Kıyıların karmaşıklığı ve çok çeşitli görevler için özel amaçlı karakterizasyonların uygulanması nedeniyle, tek, evrensel olarak kabul edilmiş bir sınıflandırma sistemi mevcut değildir. Kıyılar, jeolojik, oşinografik, atmosferik ve biyolojik faktörlerden etkilenen çeşitli gelişim biçimlerine sahip olarak çok çeşitli morfolojiler sergiler (Finkl ve Makowski, 2020).

Fiziksel özelliklere (malzeme bileşimi, dalga enerjisi gibi), biyolojik özelliklere (baskın bitki örtüsü, mercan kayalıklarının varlığı gibi), evrimsel tarihe (birincil ve ikincil kıyılar gibi) ve coğrafi oluşuma (aktif ve pasif kenarlar gibi) dayalı farklı sınıflandırma yaklaşımları önerilmiştir (Bird, 2008; Davis ve Fitzgerald, 2004). Örneğin, tektonik hareketler, volkanizma veya kara kaynaklı tortu birikimi gibi jeolojik süreçler tarafından doğrudan şekillendirilen birincil kıyılar (Inman ve Nordstrom, 1971), dalga erozyonu, biyolojik aktivite veya deniz seviyesi değişimleri gibi denizel süreçlerle önemli ölçüde değiştirilen ikincil kıyılardan (Shepard, 1940) ayrılır. Kıyıların dalga hareketi ve akıntıların yoğunluğu, yapıldıkları malzeme türü ve bu malzemelerin erozyon hızı gibi faktörlere göre ayırt edilebilir (Komar, 1998).

Bu tezin odak noktası olan yedi kıyı alanı türü, çeşitli sınıflandırma şemalarında tanımlanmış ve açıklanmıştır. Bu ayrımda, söz konusu kıyı türlerinin uydu görüntülerinde gösterdikleri farklı spektral (yansıtım değerleri) ve dokusal (desenler) özellikler dikkate alınmıştır.

2.2.1. Kumlu kıyılar

Kumlu kıyılar, tipik olarak dalgaların ve rüzgarın etkisiyle şekillenen kum taneciklerinin varlığı ile karakterize edilir ve genellikle düz veya hafif kavisli bir yapı sergiler (Bird, 2008). Tanımlayıcı özellikleri arasında, öncelikle kuvars olmak üzere kum boyutlu parçacıklardan oluşan gevşek ve iyi ayrılmış sediment birikimi bulunur (Komar, 2018). Bu iri taneler, kumlu kıyılara karakteristik açık renkli bir görünüm kazandırır ve yüksek yansıtıcılıkları nedeniyle uydu görüntülerinde kolayca ayırt edilebilirler (Şekil 1). Bazı durumlarda, ince kumlar kil ve silt partikülleri ile birlikte koyu renkli bir çamur tabakası oluşturabilir. Ancak genel olarak kumlu kıyılar, su kuvvetleri tarafından şekillendirilmiş, hafif eğimli ve ıslak plaj kısımları olarak karşılaşılmaktadır. Yüksek poroziteleri sayesinde, suya daldırıldıktan sonra hızla drene olarak sağlam ve nispeten kararlı bir yüzey oluştururlar (Yao ve diğerleri, 2015).

Dinamik ve sürekli değişen bu ortama adapte olmuş çeşitli özel flora ve fauna için önemli habitatlar sağlayan kumlu kıyılar, ekolojik açıdan değerli bölgelerdir (Defeo ve diğerleri, 2009). Çeşitli coğrafi konumlarda bulunabilen bu kıyılar, uzun vadeli çevresel baskılara, fırtınalar gibi kısa vadeli olaylara ve insan müdahalelerine yanıt olarak sürekli değişen dinamik manzaralar oluşturur. Genellikle bulundukları bölgelerden akan nehirlerin taşıdığı büyük sediment yüklerinden etkilenirler. Bu ekolojik açıdan değerli bölgelerin izlenmesi, destekledikleri çeşitli flora ve faunanın korunması ve muhafaza edilmesi açısından hayati öneme sahiptir (Patsch ve diğerleri, 2021).

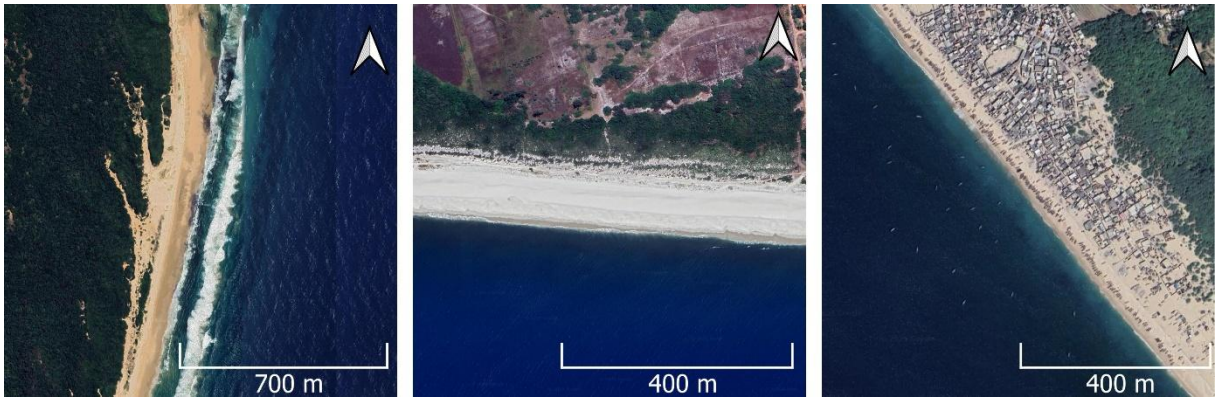

Şekil 1. Kumlu kıyılara ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.2. Kayalık kıyılar

Kayalık kıyılar, dalga erozyonu, tektonik hareketler ve kimyasal ayrışma süreçleriyle şekillenen sert, konsolide kayaç yüzeyleriyle tanımlanır (Naylor ve diğerleri, 2010). Granit, bazalt veya kireçtaşı gibi farklı litolojik bileşimlere sahip olabilirler ve genellikle dik falezler, dalga kesim platformları veya kıyı mağaraları gibi morfolojik özellikler sergilerler (Andriani ve Walsh, 2007). Uydu görüntülerinde, kayalık kıyılar yüksek kontrastlı, düzensiz dokusal desenler ve genellikle düşük yansıtıcılık gösterir; bu, kaya yüzeylerinin pürüzlü yapısından ve koyu renkli mineral içeriğinden kaynaklanır (Şekil 2). Yosun, liken veya biyolojik kabukların varlığı spektral özellikleri etkileyebilir, ancak kayalık kıyılar genellikle kumlu kıyılara göre daha sabit bir yüzey sunar (Naylor ve diğerleri, 2010).

Ekolojik olarak, kayalık kıyılar gelgit havuzlarında yaşayan deniz organizmaları, kabuklular ve kıyı kuşları için benzersiz habitatlar sağlar (Thompson ve diğerleri, 2002). Yüksek dalga enerjisi, bu alanlarda biyolojik çeşitliliği şekillendiren temel faktördür. Kayalık kıyılar, jeolojik süreçler ve fırtına olayları gibi doğal etkilere yavaşça yanıt verirken, kıyı yapılaşması ve madencilik gibi insan faaliyetleri erozyon ve habitat kaybını hızlandırabilir (Hansom, 2001). Bu kıyıların izlenmesi, jeolojik süreçlerin anlaşılması ve biyolojik çeşitliliğin korunması için kritik öneme sahiptir.



Şekil 2. Kayalık kıyılara ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.3. Haliç tipi kıyılar

Haliç tipi kıyılar, nehirlerin denizle buluştuğu ve gelgit etkilerinin belirgin olduğu geçiş bölgelerinde bulunur; çamurlu veya siltli sediment birikimi ve organik madde ile karakterize edilir (Dalrymple ve diğerleri, 1992). Bu alanlar genellikle düz, bataklık benzeri morfolojiler sergiler ve uydu görüntülerinde düşük yansıtıcılık ile homojen dokusal desenler gösterir (Şekil 3). Tuzcul bataklık bitkileri (örneğin, Spartina alterniflora) spektral imzayı şekillendirir ve yeşilimsi tonlarla belirginleşir (Kennish, 2001). Haliç tipi kıyıların dinamik yapısı, gelgit döngüleri, nehir akışı ve deniz seviyesi değişimlerine bağlı olarak sürekli değişir.

Haliçler, balıklar, kabuklular ve göçmen kuşlar için yüksek biyolojik üretkenliğe sahip kritik ekosistemlerdir (McLusky ve Elliott, 2004). Ancak, kirlilik, sediment taşınımı ve kıyı yapılaşması gibi antropojenik etkilere karşı hassastırlar. Haliç tipi kıyılar izlenmesi, karasal ve denizel ekosistemler arasındaki bağlantının korunması ve ekolojik hizmetlerin sürdürülmesi için hayati öneme sahiptir (Barbier ve diğerleri, 2011).



Şekil 3. Haliç tipi kıyılara ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.4. Antropojenik kıyılar

Antropojenik kıyılar, insan faaliyetleri tarafından şekillendirilen veya değiştirilen kıyı alanlarıdır; limanlar, dalgakıranlar, dolgu alanları ve kentsel kıyılar gibi yapıları içerir (Nordstrom, 2000). Uydu görüntülerinde düzenli geometrik desenler, yüksek yansıtıcılık (beton ve asfalt yüzeylerden kaynaklanan) ve yapay yapılarla karakterize edilir (Şekil 4). Spektral özellikler, kullanılan inşaat malzemelerine bağlı olarak değişir; beton yüzeyler açık gri tonlar

gösterirken, asfalt daha koyu tonlar sergiler (Firth ve diğerleri, 2016). Doğal kıyılara kıyasla daha homojen bir yüzey sunarlar.

Ekolojik olarak, antropojenik kıyılar doğal habitatların kaybına yol açarak biyolojik çeşitliliği azaltabilir, ancak yapay resifler gibi yapılar yeni habitatlar oluşturabilir (Dafforn ve diğerleri, 2015). Kıyı erozyonu, kirlilik ve deniz trafiği gibi insan kaynaklı baskılara karşı hassastırlar. Antropojenik kıyıların izlenmesi, sürdürülebilir kıyı yönetimi ve çevresel etkilerin azaltılması için önemlidir (Dugan ve diğerleri, 2011). İklim değişikliği ve deniz seviyesi yükselişi, bu kıyıların uzun vadeli planlamasını zorunlu kılar.



Şekil 4. Antropojenik kıyılara ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.5. Mercan resifleri

Mercan resifleri, kalsiyum karbonat salgılayan mercan poliplerinin oluşturduğu biyolojik yapılarla karakterize edilir ve tropikal sığ sularda bulunur (Spalding ve diğerleri, 2001). Uydu görüntülerinde parlak turkuaz ve yeşil tonlar sergiler; bu, sığ sulardaki mercanların yüksek yansıtıcılığından ve su altı bitki örtüsünden kaynaklanır (Şekil 5). Resif sırtları, lagünler ve kum adacıkları gibi karmaşık yapılar, dokusal desenleri belirginleştirir (Andréfouët ve diğerleri, 2003). Su derinliği ve berraklığı, spektral özellikleri etkileyen temel faktörlerdir.

Mercan resifleri, biyolojik çeşitlilik açısından dünyanın en zengin ekosistemlerinden biridir ve balıklar, kabuklular ve diğer deniz organizmaları için kritik habitatlar sunar (Moberg ve Folke, 1999). Ancak, iklim değişikliği, okyanus asitlenmesi, aşırı balıkçılık ve kirlilik

resiflerde ciddi bozulmalara neden olmaktadır (Hughes ve diğerleri, 2017). Mercan resiflerinin izlenmesi, bu kırılgan ekosistemlerin korunması ve restorasyonu için hayati öneme sahiptir.

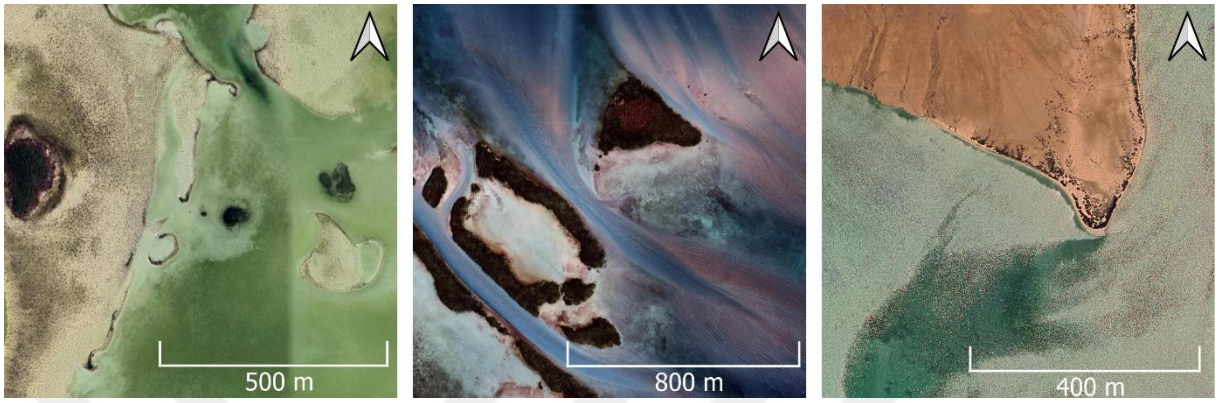

Şekil 5. Mercan resiflerine ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.6. Volkanik kıyılar

Volkanik kıyılar, lav akıntıları, piroklastik materyaller ve tüf birikintileri gibi volkanik süreçlerle şekillenir (Moore, 1975). Genellikle siyah veya koyu gri bazaltik kayaçlarla kaplıdır ve uydu görüntülerinde düşük yansıtıcılık ile pürüzlü dokusal özellikler sergiler (Şekil 6). Dalga erozyonu, dik falezler, deniz kemerleri veya volkanik kumsallar gibi dramatik morfolojiler oluşturabilir (Ramalho ve diğerleri, 2013). Spektral özellikler, mineral içeriğine ve yüzey yaşlanmasına bağlı olarak değişir; yeni lav akıntıları koyu görünürken, ayrışmış yüzeyler daha açık tonlar gösterebilir.

Ekolojik olarak, volkanik kıyılar sınırlı bitki örtüsü ve sert koşullara adapte olmuş deniz organizmaları için niş habitatlar sunar (Thornton, 2007). Aktif volkanik bölgelerde, depremler veya yeni lav akıntıları gibi olaylar kıyıları hızla değiştirebilir. Turizm ve madencilik gibi insan faaliyetleri, bu alanların doğal yapısını tehdit edebilir. Volkanik kıyıların izlenmesi, jeolojik süreçlerin ve eşsiz ekosistemlerin korunması için gereklidir (Bird, 2008).

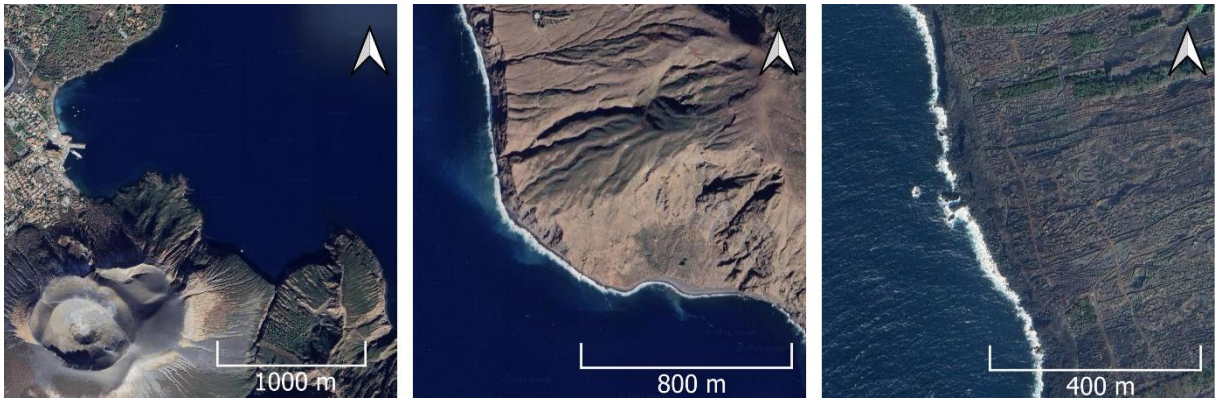

Şekil 6. Volkanik kıyılara ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.2.7. Buzul kıyıları

Buzul kıyıları, buzul erozyonu ve çökelmesiyle şekillenir; fiyortlar, moren birikintileri ve buzul vadileri gibi özellikler sergiler (Syvitski ve diğerleri, 2012). Kayaç yüzeyleri ve buzul sedimentleriyle kaplıdır ve uydu görüntülerinde yüksek kontrastlı, düzensiz desenler ile genellikle gri tonlu yansıtım değerleri gösterir (Şekil 7). Buzul çökelleri, çakıl ve kil karışımıyla heterojen bir yüzey oluşturmakta ve bu da spektral analizde karmaşık dokusal özellikler olarak ortaya çıkmaktadır (Dowdeswell ve diğerleri, 2016). İklim değişikliği, buzul geri çekilmesi ve deniz seviyesi yükselişi gibi hızlı değişimlere neden olmaktadır.

Buzul kıyıları, soğuk su ekosistemlerine ev sahipliği yapar ve foklar, deniz kuşları ve planktik organizmalar için önemli habitatlar sağlar (Benn ve Evans, 2010). İklim değişikliğinin etkilerini izlemek için doğal laboratuvarlar olarak kabul edilirler. Eriyen buzulların neden olduğu sediment akışı ve kıyı erozyonu, bu kıyıların dinamik yapısını şekillendirir. Buzul kıyılarının izlenmesi, iklimsel ve ekolojik süreçlerin anlaşılması için kritik öneme sahiptir (FitzGerald ve Hughes, 2019).

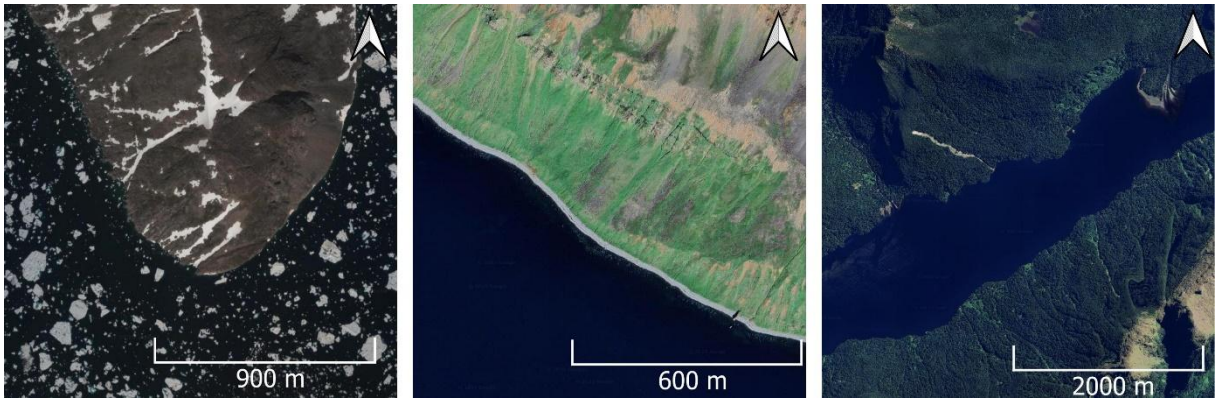

Şekil 7. Buzul kıyılarına ait örnek uydu görüntüleri (Görüntü kaynağı: Google ©2025).

2.3. Çalışma Alanı ve Örnekleme Stratejisi

Kıyı tiplerine yönelik güvenilir ve kapsamlı bir sınıflandırma modeli geliştirmek amacıyla, her bir kıyı türünün karakteristik özelliklerini temsil eden küresel ölçekte çeşitli kıyı tiplerini temsil eden bir veri seti oluşturulmasına öncelik verilmiştir. Bu amaçla, toplamda 285 birincil örnekleme lokasyonu belirlenmiştir (Şekil 8). Bu lokasyonlar, kıyı tiplerinin coğrafi ve morfolojik çeşitliliğini yansıtacak şekilde seçilmiş olup, her birincil lokasyon içinde temsil edici görüntü verileri elde etmek amacıyla alt örnekleme alanları belirlenmiştir. Küresel olarak dengeli bir veri seti, farklı kıyı sınıflarındaki varyasyonları kapsamlı bir şekilde yakalayarak modelin genellenebilirliğini artırmıştır. Örnekleme lokasyonlarının doğruluğunu sağlamak için iki aşamalı bir doğrulama süreci uygulanmıştır: (1) kapsamlı bir literatür taramasıyla çeşitli kıyı alanları belirlenmiş ve (2) yüksek çözünürlüklü uydu görüntüleri (Google Earth ve Sentinel-2 gibi), arazi fotoğrafları ve üç boyutlu görselleştirmeler gibi ek kaynaklarla doğrulama gerçekleştirilmiştir.

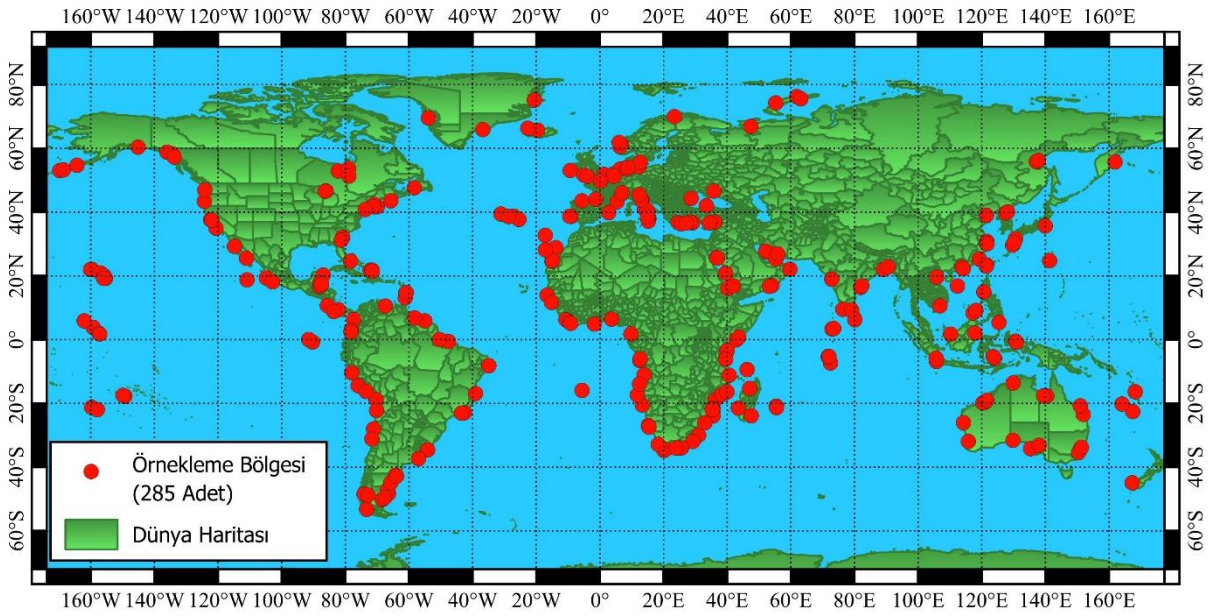

Şekil 8. Örnekleme bölgelerinin Dünya genelinde dağılımı.

Her birincil örnekleme lokasyonunda, Sentinel-2A'nın 10 metrelik çözünürlüğüne sahip bantları için 64x64 piksele karşılık gelen 640x640 metre boyutlarında alt örnekleme alanları belirlenmiştir (Şekil 9). Bu alanlar, kıyı şeridinin temsil edici bir kesitini yakalayacak şekilde seçilmiş olup, hesaplamalı olarak yönetilebilir bir veri boyutu hedeflenmiştir. Bu çalışmada kullanılan temel görüntü analiz yöntemi olan Evrişimli Sinir Ağları (CNN'ler), eğitim sürecinde çok sayıda parametrenin işlenmesini gerektirmektedir. Alt örnekleme alanlarından elde edilen 64x64 piksellik görüntüler ile kıyı şeridinin temel morfolojik ve spektral özelliklerini yakalamayı hedeflerken, model eğitimi için hesaplama yükünü azaltma arasında optimal bir denge sunulmaktadır. Ayrıca, sınıflandırma görevine anlamlı bir katkı sunmayan uzak iç kesimler ve açık deniz verileri hariç tutularak analiz yalnızca kıyı şeridine yakın bölgelere odaklanılmıştır. Bu yaklaşım, veri setinin boyutunu gereksiz yere artırmadan ilgili ve yüksek kaliteli verilerin kullanılmasını sağlamıştır.

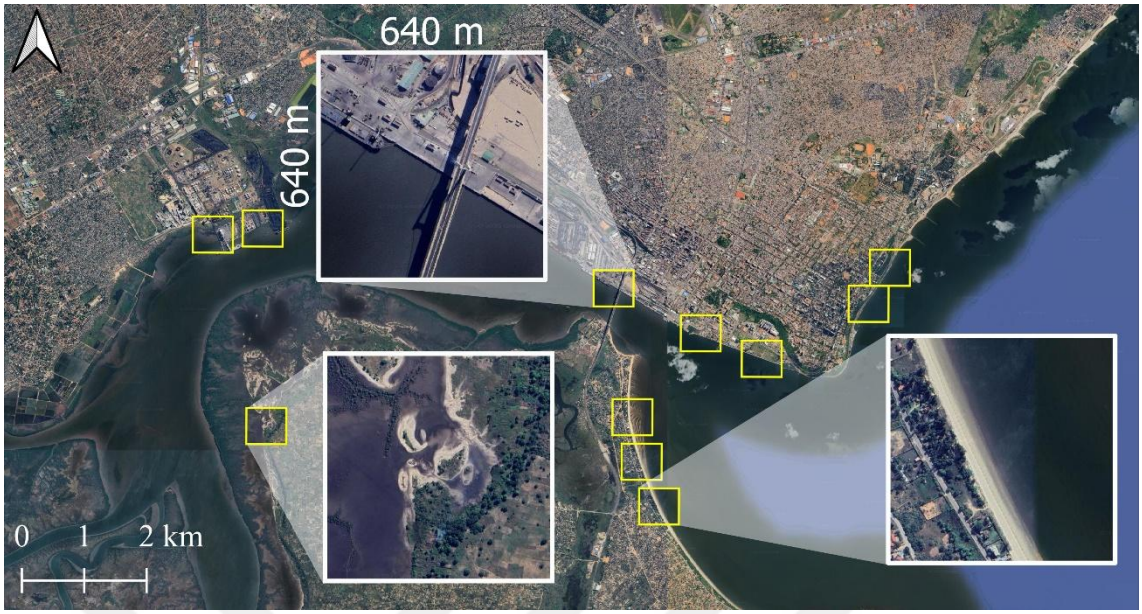

Şekil 9. Alt örnekleme işlemi (Görüntü Kaynağı: Google ©2025).

2.4. Veri Temini ve Ön İşleme

Bu çalışma, büyük ölçekli jeo-uzamsal analizler için optimize edilmiş bir bulut tabanlı platform olan Google Earth Engine (GEE) kullanılarak yürütülmüştür (Gorelick, 2013). GEE, Sentinel-2 görüntüleri de dahil olmak üzere kapsamlı Dünya gözlem verilerine hızlı ve etkin erişim sağlayarak, kıyı izleme gibi otomatikleştirilmiş iş akışlarının uygulanmasını ve büyük veri setlerinin verimli bir şekilde işlenmesini mümkün kılmaktadır (Ding ve diğerleri, 2021; Vos ve diğerleri, 2019). Çalışma alanlarına ait Sentinel-2 görüntüleri, GEE platformu üzerinden temin edilmiştir. Veri temini ve ön işleme süreçleri Şekil 10'da metodolojik akış halinde gösterilmektedir.

Veri ön işleme süreci, doğru spektral imza çıkarımını engelleyebilecek başlıca faktörlerden biri olan bulut örtüsünün filtrelenmesini içermiştir (Tarrio ve diğerleri, 2020). Bu amaçla, yalnızca %30'dan daha az bulut örtüsüne sahip mozaik görüntüler seçilmiş ve bu görüntüler, bulut yüzdesine göre önceliklendirilmiştir. Ancak, bazı piksellerde bulut kontaminasyonu riski devam edebileceğinden, görüntü sıralama ve kırpma işlemlerini takiben ikincil bir maskeleme prosedürü uygulanmıştır. GEE'nin Sentinel-2 için sağladığı "Bulut Olasılık Haritası" (20 m çözünürlük), piksel bazında bulut olasılığını değerlendirme imkanı sunarak bu süreci desteklemiştir (Main-Knorn ve diğerleri, 2017). Eğer önemli düzeyde bulut

örtüsü tespit edilirse, önceliklendirilmiş listedeki bir sonraki mozaik görüntü kullanılmıştır. Bu yinelemeli yaklaşım, nihai analiz için kullanılan görüntülerde bulut örtüsünün en aza indirilmesini sağlamıştır. Sentinel-2 görüntülerinin önceden ortorektifiye edilmiş ve atmosferik düzeltmelerden geçirilmiş olması nedeniyle (Drusch ve diğerleri, 2012), ek bir düzeltme işlemine gerek duyulmamıştır.

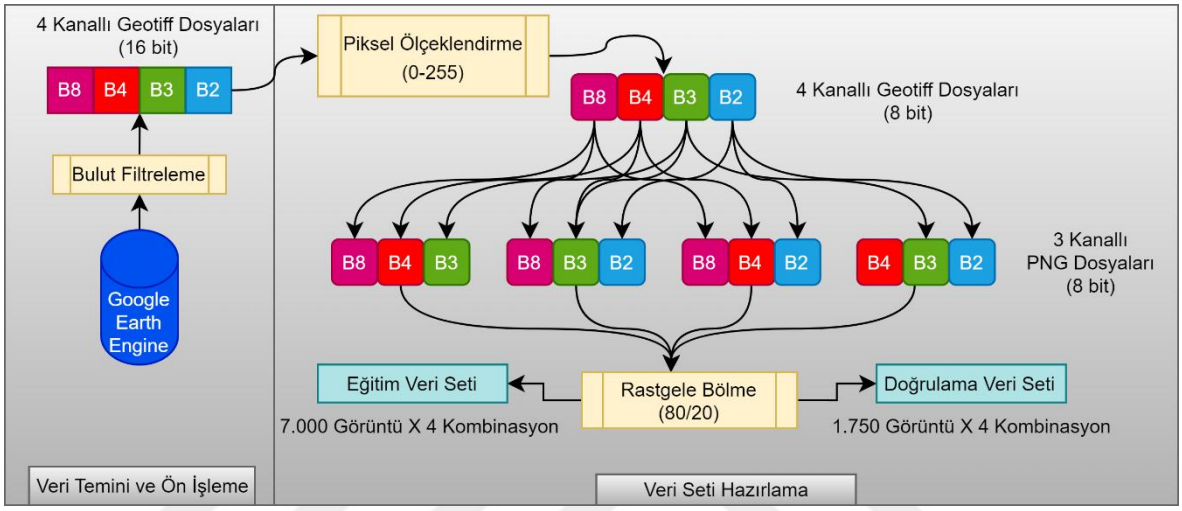

Şekil 10. Veri temini ve ön işleme süreçleri için metodolojik akış.

2.5. Veri Setinin Hazırlanması

Evrişimli Sinir Ağı (CNN) modelinin eğitimi ve doğrulanması için kullanılacak veri setleri, titiz bir hazırlık sürecinden geçirilmiştir. Google Earth Engine (GEE) platformundan elde edilen birincil veri seti, her biri 64x64 piksel boyutunda ve dört spektral bant (B2, B3, B4, B8) içeren 8.750 adet geotiff görüntüsünden oluşmaktadır (Örnekleme lokasyonlarının küresel dağılımı Şekil 8'de gösterilmektedir). Analizin açıklığı ve tutarlılığı açısından, bu bantlar sırasıyla Mavi (B), Yeşil (G), Kırmızı (R) ve Yakın Kızılötesi (NIR) olarak adlandırılmıştır. Her görüntü, yedi kıyı sınıfından birini temsil edecek şekilde düzenlenmiş olup, her sınıf için 1.250 görüntü tahsis edilmiştir.

Spektral bant kombinasyonlarının sınıflandırma performansı üzerindeki etkisini değerlendirmek amacıyla, orijinal dört banttan üçünün farklı kombinasyonlarını (örneğin, R-G-

B, NIR-G-B, NIR-R-B, NIR-R-G) içeren dört ek veri seti oluşturulmuştur. Bu yaklaşım, modelin farklı bant kombinasyonlarına duyarlılığını sistematik olarak incelemeyi sağlamıştır.

Veri setinin hazırlanması, bir dizi kritik adımı kapsamıştır. İlk olarak, veri setindeki olası önyargıları ortadan kaldırmak için görüntüler rastgele karıştırılmıştır (Deshmukh ve diğerleri, 2015). İkinci olarak, her görüntünün piksel yoğunluk değerleri, tutarlı bir gösterim sağlamak üzere 0 ile 255 arasında ölçeklendirilmiştir. Bu işlem, farklı görüntüler arasında spektral verilerin standartlaştırılmasını temin etmiştir. Son olarak, ölçeklendirilmiş geotiff görüntüler, CNN modelinin gereksinimlerine uygun bir formata dönüştürülerek 3 kanallı PNG dosyalarına çevrilmiştir (Şekil 11).

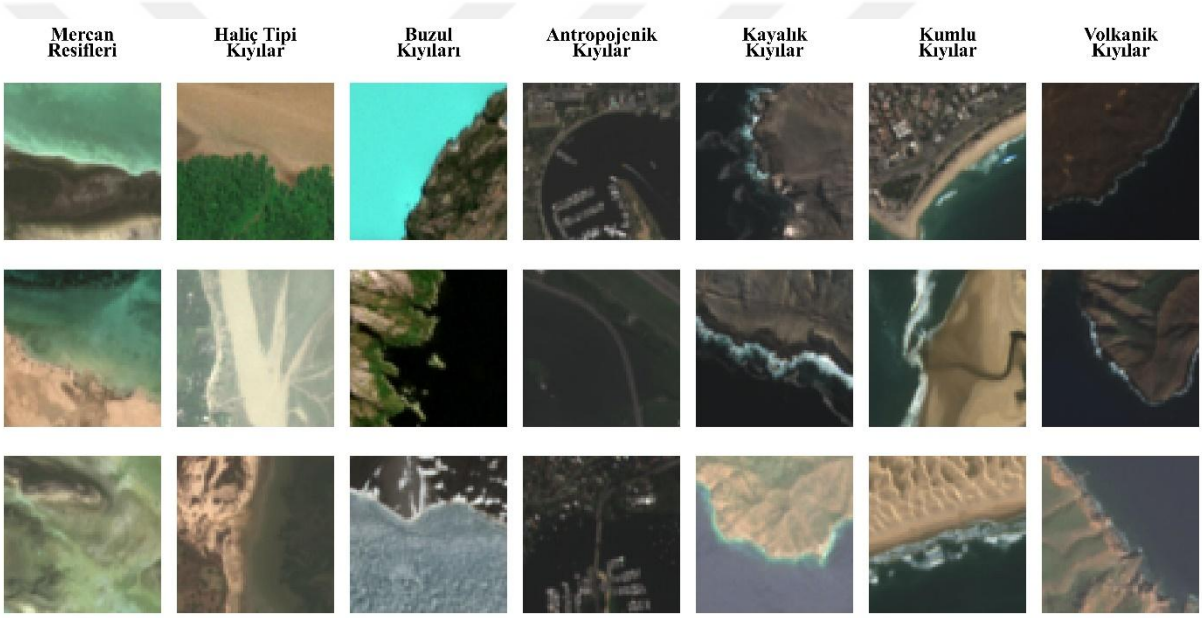

Şekil 11. Veri setinden rastgele seçilen örnekler.

Hazırlık sürecinin son aşaması, veri setlerinin eğitim ve doğrulama alt setlerine bölünmesini içermiştir. Eğitim seti, her kıyı sınıfı için 1.000 görüntü olacak şekilde, her bant kombinasyonu için toplam 7.000 görüntüden oluşmaktadır. Doğrulama seti ise her sınıf için 250 görüntü içermekte olup, toplamda 1.750 görüntüye ulaşılmıştır. Bu %80/%20'lik ayrım, hem eğitim hem de doğrulama setlerinde tüm kıyı sınıflarının dengeli bir şekilde temsil edilmesini sağlamıştır. Söz konusu dengeli temsil, CNN modelinin etkin bir şekilde eğitilmesi

ve performansının güvenilir bir şekilde değerlendirilmesi açısından kritik öneme sahiptir (Zelaya, 2019).

2.6. Modifiye Edilen VGG16 Mimarisi

Evrişimli Sinir Ağları (CNN), özellikle görüntü analizi için tasarlanmış derin öğrenme modelleri arasında öne çıkmaktadır (Krizhevsky ve diğerleri, 2012). Bu modeller, konvolüsyonel katmanlar, havuzlama (pooling) katmanları ve tam bağlı (fully connected) katmanlardan oluşan çok katmanlı bir yapıya sahiptir (LeCun ve diğerleri, 2015). Konvolüsyonel katmanlar, görüntüler üzerinde filtreler uygulayarak sınıflandırma için kritik özellikleri çıkarır (Zeiler ve Fergus, 2014). Havuzlama katmanları, özellik haritalarının boyutunu küçülterek hesaplama karmaşıklığını azaltır ve genelleştirme kapasitesini artırır (Bačanin Džakula, 2019). Ağın son aşamasında yer alan tam bağlı katmanlar ise çıkarılan özelliklere dayanarak nihai sınıflandırma işlemini gerçekleştirir (Krizhevsky ve diğerleri, 2012).

VGG16, sadeliği ve yüksek performansıyla tanınan bir CNN mimarisidir (Simonyan ve Zisserman, 2014). Visual Geometry Group (VGG) tarafından 2014 yılında geliştirilen bu model, 13 konvolüsyonel katman, 5 havuzlama katmanı ve 3 tam bağlı katmandan oluşan toplam 16 katmanlı bir yapıya sahiptir (Vedaldi ve Zisserman, 2016) (Şekil 12). VGG16'nın temel gücü, derin bir ağ yapısını korurken parametre sayısını nispeten düşük tutabilmesidir. Tüm konvolüsyonel katmanlar, 3x3 piksel boyutunda filtreler ve 1 piksel adımla (stride) çalışırken, havuzlama katmanları 2x2 piksel boyutunda ve 1 piksel adımla uygulanır (Naranjo-Torres ve diğerleri, 2020). Bu tasarım, modelin hem etkinliğini hem de hesaplama verimliliğini artırmaktadır.

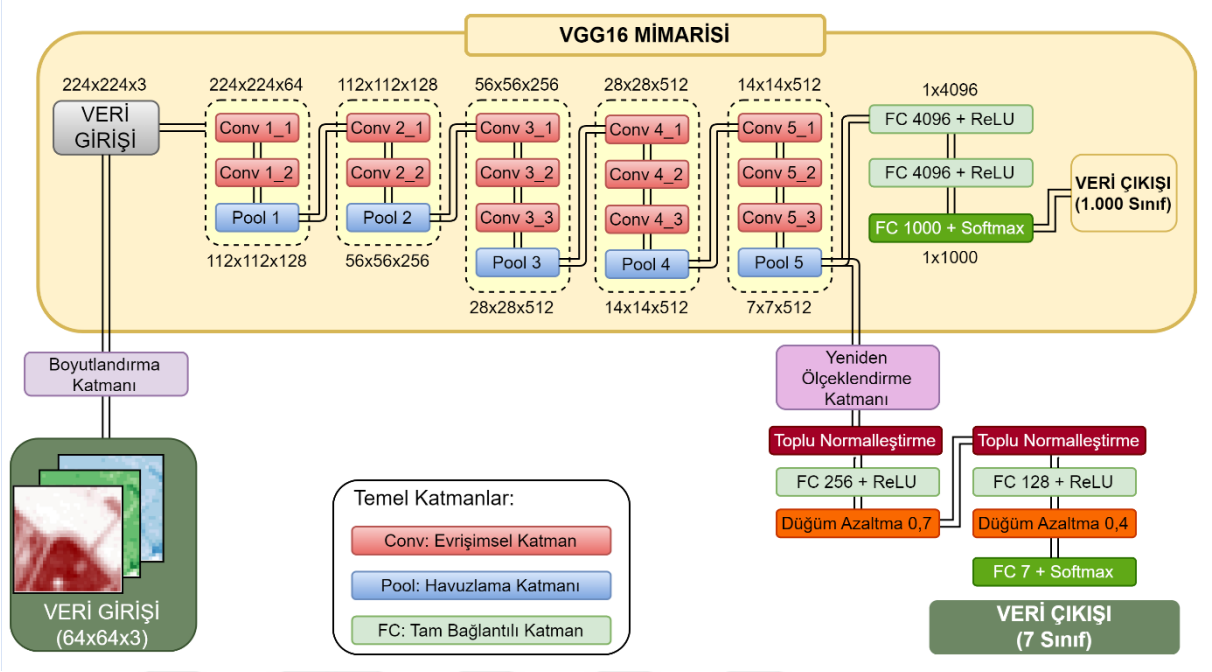

Şekil 12. VGG16 orijinal mimarisi (üst panel) ve bu çalışmada yedi kıyı sınıfını sınıflandırmak üzere uygulanan modifikasyonlar (alt panel).

Bu çalışma kapsamında, yedi farklı kıyı sınıfını sınıflandırmak üzere temel model olarak VGG16 CNN mimarisi seçilmiş ve modele özel modifikasyonlar uygulanmıştır (Şekil 12). Modifiye edilmiş mimari, yaklaşık 22 milyon parametre içermektedir. Girdi verilerinin ön işlenmesi, görüntü boyutlarının ve piksel değerlerinin model gereksinimlerine uygun hale getirilmesini kapsamıştır. VGG16'nın standart giriş boyutlarına uyum sağlamak için bir boyutlandırma (resize) katmanı eklenmiştir. Bu katman, girdi görsellerinin 64x64 piksel olan boyutlarını 224x224 piksel boyutlarına artırmaktadır. Ardından piksel değerlerini 0 ile 1 aralığına normalize eden bir yeniden ölçeklendirme (rescaling) katmanı kullanılmıştır. Bu işlem, eğitim sürecinin stabilitesini ve verimliliğini artırmayı amaçlamıştır (Lee ve diğerleri, 2019).

Özellik çıkarımı sürecinde, son konvolüsyonel katmanın çıktısı, nihai sınıflandırma için uygun bir tek boyutlu vektöre dönüştürülmüştür. Eğitim stabilitesini güçlendirmek ve aşırı öğrenme (overfitting) riskini azaltmak amacıyla, konvolüsyonel katmanların ardından toplu normalizasyon (batch normalization) katmanları entegre edilmiştir (Garbin ve diğerleri, 2020). Çıktı katmanında ise, orijinal tam bağlı katmanlar, yedi sınıflı kıyı sınıflandırma görevine özgü

bir katman dizisiyle değiştirilmiştir. Bu yeni katmanlar, aşırı öğrenmeyi önlemek için Düğüm Azaltma (dropout) katmanları ve özellik çıkarımı ile sınıflandırma için uygun aktivasyon fonksiyonlarını içermektedir. Nihai yoğun katman, 7 birim ve softmax aktivasyon fonksiyonu ile yapılandırılmış, böylece modelin her bir görüntü için en olası kıyı sınıfını belirleyebilmesi sağlanmıştır (Sharma ve diğerleri, 2017).

2.7. Transfer Öğrenimi

Bu çalışmada VGG16 modeli sıfırdan başlatılan ağırlıklarının yanı sıra, milyonlarca etiketli görüntü içeren ImageNet veri seti üzerinde önceden eğitilmiş VGG16 modeli, ince ayar (fine-tuning) yöntemiyle kullanılmıştır (Deng ve diğerleri, 2009). ImageNet'in geniş çeşitliliği, modelin farklı görüntü işleme görevlerine aktarılabilecek temel ve genelleştirilebilir özellikler çıkarabilmesini sağlamaktadır (Krizhevsky ve diğerleri, 2012; Yosinski ve diğerleri, 2014). Transfer öğrenme, önceden öğrenilmiş bu özelliklerin kıyı sınıflandırma gibi özel bir göreve uyarlanmasını mümkün kılarak, modelin eğitim süresini kısaltmakta ve genelleme performansını artırmaktadır.

Uygulanan ince ayar yaklaşımında, VGG16'nın ilk üç konvolüsyonel bloğuna ait ağırlıklar sabitlenmiş, böylece bu katmanların önceden öğrenilmiş özellikleri korunmuştur. Buna karşılık, son iki konvolüsyonel blok (4. ve 5. katmanlar) yeniden eğitime tabi tutularak modelin kıyı görüntülerinin özgün dokusal ve spektral özelliklerine uyarlanması sağlanmıştır (Tammina, 2019). Bu strateji, önceden öğrenilmiş genelleştirilmiş özelliklerin avantajlarından faydalanırken, modelin görev-özel gereksinimlere adaptasyonunu dengelemektedir.

Sadece son konvolüsyonel katmanların ince ayar yapılması, eğitim süresini önemli ölçüde azaltmış ve modelin daha önce görülmemiş kıyı görüntülerine genelleme yeteneğini güçlendirmiştir. Bu yaklaşım, kumlu, kayalık, bitki örtüsüyle kaplı veya antropojenik kıyılar gibi farklı dokusal özelliklere sahip kıyı sınıflarının daha iyi ayırt edilmesini sağlamıştır. Ek-1'de verilen eğitim ve doğruluk grafiklerinin gösterdiği üzere, önceden eğitilmiş ağırlıklarla başlatılan model, yalnızca 20 öğrenme adımı (epoch) sonunda eğitim verisine yüksek uyum sağlarken, varsayılan ağırlıklarla başlatılan modelde bu süre 40 öğrenme adımına ulaşmaktadır.

Transfer öğrenmenin avantajı, özellikle uydu görüntülerinde belirgin olan kıyı özelliklerinin kendine özgü dokusal yapılarından kaynaklanmaktadır. Kum, kaya, bitki örtüsü ve insan yapımı yapılar gibi unsurlar, farklı spektral ve dokusal imzalar sergiler. ImageNet'ten öğrenilen genelleştirilmiş özellikler, bu dokuları etkili bir şekilde yakalayarak, ince ayar

yapılmış VGG16 modelinin kıyı görüntülerini yüksek doğrulukla sınıflandırmasına olanak tanımıştır.

Bu bağlamda, çalışmanın sonuç bölümünde, sıfırdan başlatılan ağırlıklarla eğitilen bir modelin performansı ile transfer öğrenimi yoluyla elde edilen önceden eğitilmiş ağırlıklarla ince ayar (tuning) yapılan modelin performansı karşılaştırılacak ve transfer öğreniminin kıyı sınıflandırma görevindeki etkinliği nicel olarak değerlendirilecektir.

2.8. Derin Öğrenme Modeli için Eğitim ve Doğrulama Konfigürasyonu

Kıyı sınıflandırması için geliştirilen CNN modeli, TensorFlow Python kütüphanesi kullanılarak uygulanmıştır (Abadi ve diğerleri, 2015). Modelin eğitimi, performansın optimize edilmesi ve genelleştirme kapasitesinin artırılması amacıyla aşağıdaki konfigürasyonlarla gerçekleştirilmiştir:

Kayıp Fonksiyonu: Çok sınıflı sınıflandırma problemleri için uygun olan Seyrek Kategorik Çapraz Entropi (Sparse Categorical Crossentropy fonksiyonu) seçilmiştir. Bu fonksiyon, yedi kıyı sınıfını temsil eden ayrık tam sayı etiketleriyle model tahminleri arasındaki farkı ölçerek, hata minimizasyonunu yönlendirmektedir (Bao ve diğerleri, 2021). Bu seçim, modelin sınıflandırma doğruluğunu artırırken hesaplama verimliliğini de desteklemiştir.

Optimizasyon Algoritması: RMSprop (Karekök Ortalama Yayılımı (Root Mean Square Propagation)) optimizatörü tercih edilmiştir. Bu algoritma, gradyan tabanlı öğrenme yaklaşımıyla ağırlıkları güncelleyerek kayıp fonksiyonunu en aza indirmeyi hedefler ve eğitim sürecinde ağırlıkların etkin bir şekilde ayarlanmasını sağlar (Vani ve Rao, 2019). RMSprop'un uyarlanabilir öğrenme hızı, modelin farklı veri özelliklerine hızlı bir şekilde uyum sağlamasına olanak tanımıştır.

Performans Ölçütü: Model performansının izlenmesi için birincil metrik olarak doğruluk (accuracy) belirlenmiştir. Doğruluk, modelin yedi kıyı sınıfından doğru sınıflandırdığı görüntülerin oranını ifade ederek, öğrenme ilerlemesini ve iyileştirme gerektiren alanları açıkça ortaya koymaktadır (Bao ve diğerleri, 2021). Bu metrik, modelin hem eğitim hem de doğrulama setlerinde dengeli bir performans sergilemesini değerlendirmek için kullanılmıştır.

Öğrenme Hızı Zamanlayıcısı: Eğitim sürecinde öğrenme hızını dinamik olarak ayarlamak amacıyla bir zamanlayıcı uygulanmıştır. Bu yöntem, doğrulama doğruluğunun belirli bir sayıda epoch boyunca iyileşmemesi durumunda öğrenme hızını %50 oranında azaltarak, modelin aşırı öğrenmesini (overfitting) önlemeyi ve daha iyi genelleştirme sağlamayı

amaçlamaktadır (Santos ve Papa, 2022). Bu strateji, modelin daha hassas bir şekilde optimize edilmesini ve kayıp fonksiyonunda daha iyi yakınsama elde edilmesini desteklemiştir (Wen ve diğerleri, 2020).

2.9. Spektral Analizler

Spektral analizler, yedi kıyı tipinin (Kumlu Kıyılar, Antropojenik Kıyılar, Kayalık Kıyılar, Haliç Tipi Kıyılar, Volkanik Kıyılar, Mercan Resifleri, Buzul Kıyıları) Sentinel-2 uydu görüntülerinden elde edilen bant reflektans değerlerinin (Dijital Numara - DN) istatistiksel dağılımlarını karakterize etmek amacıyla gerçekleştirilmiştir (Drusch ve diğerleri, 2012). Bu analizler, her bir kıyı sınıfının Mavi (B), Yeşil (G), Kırmızı (R) ve Yakın Kızılötesi (NIR) bantlarındaki spektral özelliklerini sistematik bir şekilde değerlendirmeyi ve sınıflandırma modelinin bu özellikleri nasıl kullandığını anlamayı hedeflemiştir. Spektral analizlerin temel amacı, kıyı tiplerinin ayırt edici spektral imzalarını ortaya koyarak modelin sınıflandırma performansına katkı sağlayan bant kombinasyonlarını belirlemektir. Bu bağlamda, her bant için kıyı tiplerine ait reflektans değerlerinin istatistiksel özetleri (ortalama, standart sapma, minimum, maksimum ve çeyreklik değerler) hesaplanmış ve bu değerler tablo formatında sunulmuştur. Tabloların yanı sıra görsel yorumlamayı kolaylaştırmak amacıyla, violin grafikleri ile tüm bant değerleri sunulmuştur (Hintze ve Nelson, 1998).

2.10. Dokusal Analizler

Dokusal analizler, Sentinel-2 verilerinden elde edilen bant reflektans değerlerine dayalı spektral özellikler ile Gri Seviye Eş-Oluşum Matrisi (GLCM) tabanlı dokusal özelliklerin varyasyonlarını incelemeyi ve modelin bu özellikleri etkin bir şekilde kullanma yeteneğini değerlendirmeyi hedeflemiştir (Haralick ve diğerleri, 1973). Dokusal analizler, GLCM tabanlı beş ölçüt (Kontrast, Benzeşmezlik, Homojenlik, Enerji ve Korelasyon) kullanılarak gerçekleştirilmiştir. GLCM, 5x5 piksel boyutunda bir pencere kullanılarak ve dört farklı yönde (0°, 45°, 90°, 135°) hesaplanmıştır. Her bir ölçüt, gri seviye değerleri 8 bit (256 seviye) olarak kuantize edilerek elde edilmiştir (Hall-Beyer, 2017). Her bir ölçüt için kıyı tiplerine ait istatistiksel özetler (ortalama, standart sapma, minimum, maksimum ve çeyreklik değerler) hesaplanmış ve tablo formatında sunulmuştur. Ayrıca, bu ölçütlerin kıyı tipleri arasındaki dağılımlarını görselleştirmek amacıyla kutu grafikleri oluşturulmuştur. Dokusal analizlerin amacı, kıyı tiplerinin dokusal heterojenliklerini ve düzenli desenlerini karakterize ederek

modelin sınıflandırma performansına olan katkılarını değerlendirmektir. Aşağıda, kullanılan GLCM ölçütleri ve hesaplama yöntemleri açıklanmaktadır:

2.10.1. Kontrast (Contrast)

Bir piksel ile komşuları arasındaki gri seviye farkını ölçer. Bu ölçüt, dokusal heterojenliği ve keskin geçişlerin yoğunluğunu belirlemek için kullanılır. Formülü şu şekildedir:

$$Kontrast = \sum_{i,j} |i-j|^2 \, p(i,j) \tag{2.1}$$

Burada p(i,j), GLCM'nin normalize edilmiş elemanıdır ve (i,j), gri seviye değerlerini temsil eder.

2.10.2. Benzeşmezlik (Dissimilarity)

Yerel gri seviye değişimlerini ölçer. Kontrasta benzer bir işlev görerek dokusal düzensizlikleri değerlendirmede etkilidir. Formülü şu şekildedir:

$$Benzeşmezlik = \sum_{i,j} |i-j| \, p(i,j) \tag{2.2}$$

Burada p(i,j), GLCM'nin normalize edilmiş elemanıdır ve (i,j), gri seviye değerlerini temsil eder.

2.10.3. Homojenlik (Homogeneity)

Komşu piksellerin gri seviye benzerliğini ölçer. Bu ölçüt, dokusal pürüzsüzlük ve tekdüzeliği analiz etmek için kullanılır. Formülü şu şekildedir:

$$Homojenlik = \sum_{i,j} \frac{p(i,j)}{1+|i-j|} \tag{2.3}$$

Burada p(i,j), GLCM'nin normalize edilmiş elemanıdır ve (i,j), gri seviye değerlerini temsil eder.

2.10.4. Enerji (Energy)

GLCM'deki kare değerlerinin toplamını ifade eder ve gri seviyelerinin tekdüzeliğini ölçer. Formülü şu şekildedir:

$$Enerji = \sum_{i,j} p(i,j)^2 \tag{2.4}$$

Burada p(i,j), GLCM'nin normalize edilmiş elemanıdır ve (i,j), gri seviye değerlerini temsil eder.

2.10.5. Korelasyon (Correlation)

Bir pikselin gri seviyesi ile komşu pikselin gri seviyesi arasındaki doğrusal ilişkiyi ölçer. Dokusal düzenliliği değerlendirir ve formülü şu şekildedir:

$$Korelasyon = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i\,\sigma_j} \tag{2.5}$$

Burada μ_i, μ_j sırasıyla satır ve sütun gri seviye ortalamaları; σ_i, σ_j standart sapmalardır.

Bu analizlerin sonuçları, modelin sınıflandırma performansını destekleyen tamamlayıcı bilgiler sunmuş ve kıyı sınıfların dokusal imzalarını ayırt etmede modelin başarısını değerlendirmiştir. GLCM tabanlı dokusal özellikler, modelin dokusal heterojenlikleri ve düzenli desenleri nasıl işlediğini anlamada güçlü bir araç olmuştur (Haralick ve diğerleri, 1973).

2.11. Model Performansı Değerlendirme Yöntemleri

Evrişimli Sinir Ağı (CNN) modelinin kıyı sınıflandırma performansını değerlendirmek amacıyla, farklı spektral bant kombinasyonları kullanılarak kapsamlı deneyler yürütülmüştür. Modelin her bir kıyı sınıfındaki başarımı, nicel metrikler aracılığıyla sistematik olarak analiz edilmiştir. Modelin her bir kıyı sınıfındaki başarımı, nicel metrikler aracılığıyla sistematik olarak analiz edilmiştir. Performans değerlendirmesi, aşağıdaki yöntemler kullanılarak çok yönlü bir şekilde gerçekleştirilmiştir:

2.11.1. Genel doğruluk ve eğitim/doğrulama değerleri

Modelin genel sınıflandırma başarısını değerlendirmek için genel doğruluk oranları hesaplanmış ve farklı bant kombinasyonlarına göre karşılaştırılmıştır. Ayrıca, modelin öğrenme sürecini analiz etmek amacıyla eğitim ve doğrulama veri setleri üzerindeki kayıp (loss) ve doğruluk (accuracy) gibi performans metrikleri incelenmiş, ve modelin veri setine uyum sağlama süreçleri değerlendirilmiştir.

2.11.2. Karışıklık matrisi (confusion matrix)

Modelin sınıflandırma performansını ayrıntılı bir şekilde özetleyen görsel bir tablodur. Matrisin satırları gerçek sınıfları, sütunları ise modelin tahmin ettiği sınıfları temsil eder (Susmaga, 2004). Diyagonal üzerindeki yüksek değerler doğru sınıflandırmaları ifade ederken, diyagonal dışındaki değerler yanlış sınıflandırmaların hangi sınıflar arasında gerçekleştiğini gösterir. Bu tablo, her bir kıyı sınıfı için isabetli ya da hatalı tahmin yüzdelerini detaylı bir şekilde inceleme ve modelin sınıf bazındaki güçlü ve zayıf yönlerini belirleme imkanı sunmaktadır. Karışıklık matrisleri, tüm bant kombinasyonları için genel olarak ve her bir bant kombinasyonu (R-G-B, NIR-G-B, NIR-R-G, NIR-R-B) için ayrı ayrı analiz edilmiştir.

2.11.3. Alıcı işletim karakteristiği (roc) eğrisi

ROC (Receiver Operating Characteristic) Eğrisi Modelin sınıflar arasındaki ayırt edicilik kapasitesini görselleştiren grafiksel bir araçtır. Her bir kıyı sınıfının performansını ayrı ayrı değerlendirmek için “bire karşı tümü” (one-vs-all) yaklaşımı izlenmiştir. Bu yaklaşımda, incelenen sınıf pozitif sınıf olarak tanımlanırken, diğer tüm sınıflar negatif sınıf olarak kabul edilir. ROC eğrisi, farklı eşik değerlerinde Doğru Pozitif Oranı (True Positive Rate, TPR) ile Yanlış Pozitif Oranı (False Positive Rate, FPR) arasındaki ilişkiyi gösterir. Eğrinin altındaki alan (Area Under the Curve, AUC) değeri yüksek olan modeller, spektral özelliklere dayalı olarak sınıflar arasında daha etkili bir ayrım yapabilmektedir (Fan ve diğerleri, 2006). ROC eğrileri, modelin spektral ayırt ediciliğini tamamlayıcı bir şekilde değerlendirmek için kullanılmıştır.

3. BULGULAR

Bu bölümde, spektral ve dokusal özellikler ile model performansı sonuçları, kıyı tiplerinin sınıflandırılmasına dair kapsamlı bir analiz sunmak üzere detaylı bir şekilde sunulmuştur. Yedi kıyı sınıfı (Kumlu Kıyılar, Antropojenik Kıyılar, Kayalık Kıyılar, Haliç Tipi Kıyılar, Volkanik Kıyılar, Mercan Resifleri, Buzul Kıyıları) için 1,250 görüntülük veri seti kullanılmıştır. Bulgular, spektral analiz, dokusal analiz ve model performansı başlıkları altında düzenlenmiş, her başlık sınıfların özelliklerini ve modelin sınıflandırma başarısını tablo ve şekillerle açık bir şekilde ortaya koymaktadır.

3.1. Spektral Analiz Bulguları

Spektral analiz, sınıfların spektral imzalarını belirleyerek sınıflandırma sürecinin temelini oluşturmuştur. Mavi, Yeşil, Kırmızı ve Yakın Kızılötesi (NIR) bantlardaki yansıma değerleri, kıyı sınıflarının yüzey özelliklerini karakterize etmek için incelenmiştir. Her bant için tanımlayıcı istatistikler hesaplanmış, yansıma değerlerinin sınıflar arasındaki farklılıkları violin grafikleriyle görselleştirilmiştir. Aşağıda, her bant için sonuçlar, sınıfların spektral özelliklerini öne çıkaracak şekilde sunulmaktadır.

3.1.1. Mavi bant yansıma değerleri

Mavi bant, özellikle su içeriği yüksek veya parlak yüzeylere sahip kıyı sınıflarının yansıma özelliklerini belirginleştirmede önemli bir rol oynar. Sığ sulardaki tortu birikimleri ve açık renkli yüzeyler, bu bantta nispeten yüksek yansıma değerleri sergileyebilir. Kıyı sınıflarının Mavi bant yansıma değerleri, 1,250 görüntülük veri seti üzerinden analiz edilmiştir. Tanımlayıcı istatistikler Tablo 2'de sunulmuştur. Mercan Resifleri, 2,118 ortalama yansıma değeriyle en yüksek yansımayı gösterirken, Volkanik Kıyılar 1,051 ortalama ile en düşük yansıma değerine sahiptir. Buzul Kıyıları, 1,874 standart sapma ve 10,182 maksimum yansıma değeriyle geniş bir aralıkta yansıma değerleri göstermiştir.

Tablo 2. Mavi bant için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	1.928	566	394	1.615	1.852	2.216	3.750
Antropojenik Kıyılar	1.250	1.734	324	508	1.529	1.690	1.877	3.123
Kayalık Kıyılar	1.250	1.636	438	185	1.387	1.610	1.899	3.223
Haliç Tipi Kıyılar	1.250	1.408	528	140	1.305	1.439	1.684	2.957
Volkanik Kıyılar	1.250	1.051	544	152	428	1.315	1.473	2.620
Mercan Resifleri	1.250	2.118	769	144	1.676	2.196	2.667	5.190
Buzul Kıyıları	1.250	1.735	1.874	43	737	1.158	1.718	10.182

Yansıma değerlerinin sınıflar arasındaki dağılımı, spektral özelliklerin yoğunluk aralıklarını görselleştirmek için Şekil 13'de violin grafiği ile sunulmuştur. Grafik, Mercan Resifleri ve Buzul Kıyıları'nın geniş yansıma aralıklarını, Volkanik Kıyılar'ın ise sıkışık dağılımını açıkça ortaya koymaktadır.

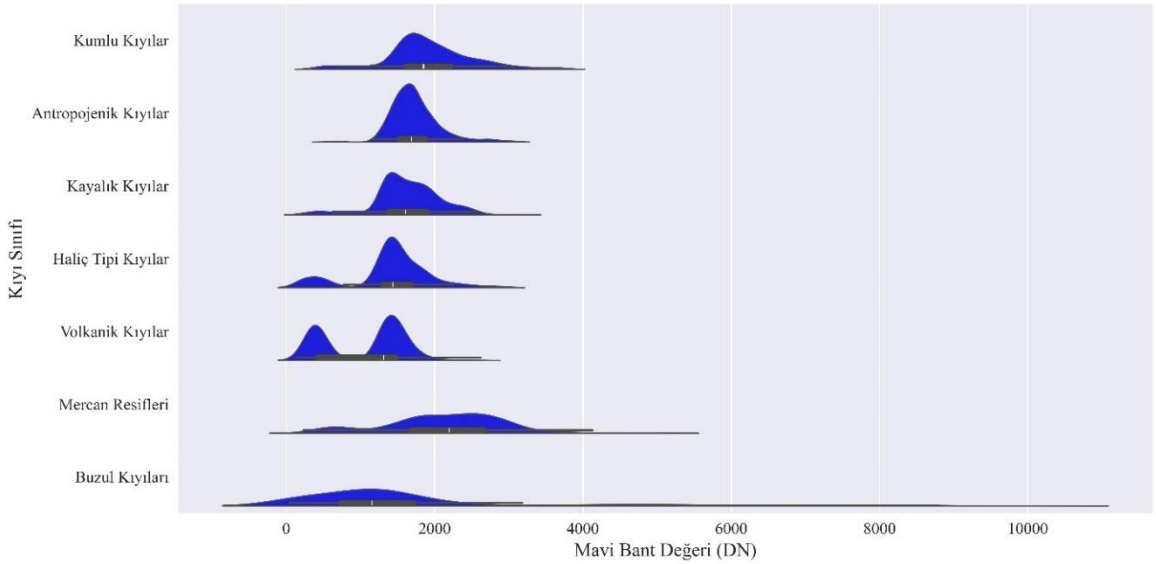

Şekil 13. Mavi bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği).

3.1.2. Yeşil bant yansıma değerleri

Yeşil bant, özellikle bitki örtüsü yoğun alanların ve su yüzeylerinin yansıma özelliklerini ortaya çıkarmada etkilidir. Bu bantta, bitki örtüsü ve sığ sular genellikle yüksek yansıma değerleri sergiler. Kıyı sınıflarının Yeşil bant yansıma değerleri, yüzey özelliklerini ayrıntılı bir şekilde incelemek için analiz edilmiştir. Tanımlayıcı istatistikler Tablo 3'de sunulmuştur. Mercan Resifleri, 2,462 ortalama yansıma değeriyle en yüksek yansımayı gösterirken, Volkanik Kıyılar 1,120 ortalama ile en düşük yansıma değerine sahiptir. Buzul Kıyıları, 1,831 standart sapma ile geniş bir yansıma aralığı göstermiştir.

Tablo 3. Yeşil bant için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	2.206	616	602	1.843	2.111	2.541	4.096
Antropojenik Kıyılar	1.250	1.906	370	707	1.661	1.856	2.061	3.566
Kayalık Kıyılar	1.250	1.802	500	198	1.496	1.761	2.118	3.557
Haliç Tipi Kıyılar	1.250	1.675	593	309	1.507	1.673	1.953	3.594
Volkanik Kıyılar	1.250	1.120	545	138	516	1.377	1.528	3.008
Mercan Resifleri	1.250	2.462	942	304	1.846	2.533	3.201	5.715
Buzul Kıyıları	1.250	1.811	1.831	79	920	1.304	1.783	10.164

Yeşil bant yansıma değerlerinin dağılımı, sınıfların yüzey özelliklerindeki farklılıkları görselleştirmek için Şekil 14'de violin grafiği ile sunulmuştur. Grafik, Mercan Resifleri'nin yüksek yansıma değerlerini ve Buzul Kıyıları'nın geniş dağılımını öne çıkarmaktadır.

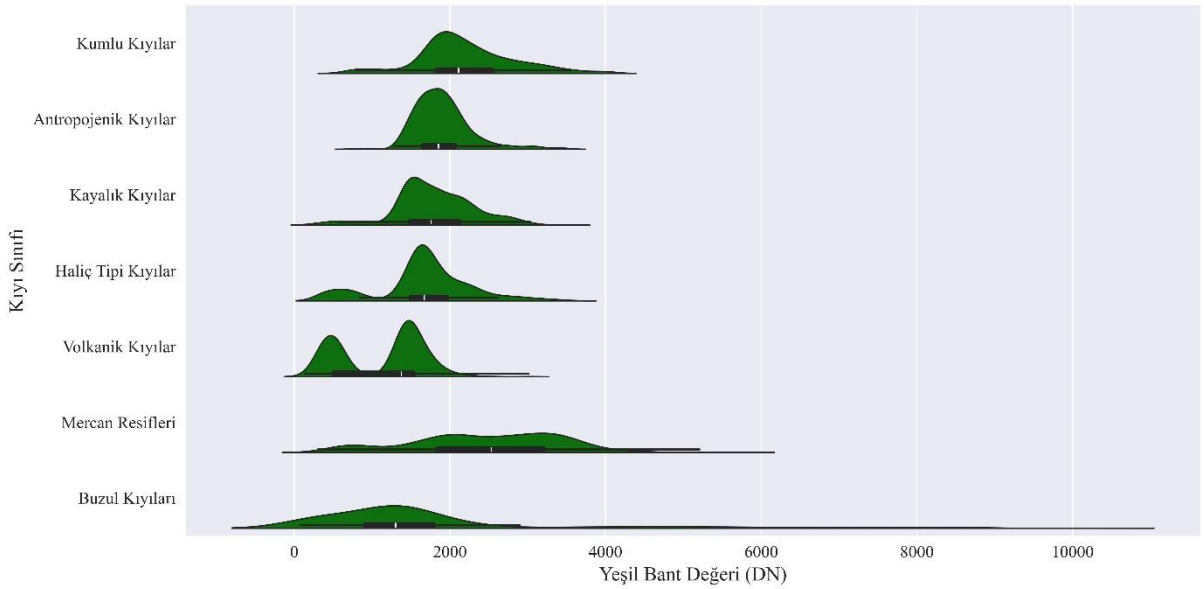

Şekil 14. Yeşil bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği).

3.1.3. Kırmızı bant yansıma değerleri

Kırmızı bant, yüzey özelliklerinin ve bitki örtüsünün ayrımında önemli bilgiler sağlar. Bitki örtüsü olmayan yüzeyler bu bantta nispeten düşük yansıma değerleri gösterirken, açık renkli yüzeylerden daha yüksek değerler elde edilebilir. Kıyı sınıflarının Kırmızı bant yansıma değerleri, yüzey özelliklerini analiz etmek için incelenmiştir. Tanımlayıcı istatistikler Tablo 4'te sunulmuştur. Kumlu Kıyılar, 2,159 ortalama yansıma değeriyle en yüksek yansımayı gösterirken, Volkanik Kıyılar 1,053 ortalama ile en düşük yansıma değerine sahiptir. Mercan Resifleri (1,115 standart sapma) ve Buzul Kıyıları (1,840 standart sapma) geniş yansıma aralıkları sergilemiştir.

Tablo 4. Kırmızı bant için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	2.159	649	400	1.740	2.059	2.565	4.255
Antropojenik Kıyılar	1.250	1.897	406	666	1.617	1.838	2.093	3.832
Kayalık Kıyılar	1.250	1.792	576	108	1.396	1.748	2.153	3.641
Haliç Tipi Kıyılar	1.250	1.680	707	143	1.411	1.643	2.036	4.075
Volkanik Kıyılar	1.250	1.053	579	87	415	1.281	1.465	3.332
Mercan Resifleri	1.250	2.141	1.115	48	1.343	2.024	3.105	5.385
Buzul Kıyıları	1.250	1.636	1.840	18	508	1.156	1.607	10.234

Kırmızı bant yansıma değerlerinin dağılımı, sınıfların spektral varyasyonlarını görselleştirmek için Şekil 15'te violin grafiği ile sunulmuştur. Grafik, Kumlu Kıyılar ve Mercan Resifleri'nin yüksek yansıma değerlerini, Volkanik Kıyılar'ın ise düşük değerlerini vurgulamaktadır.

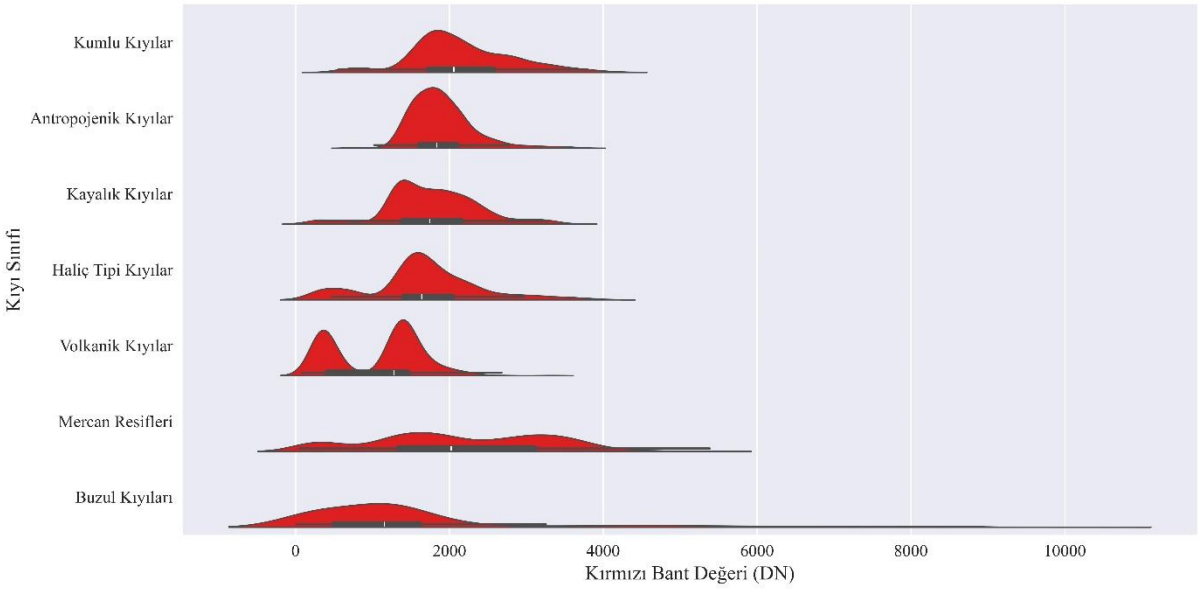

Şekil 15. Kırmızı bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği).

3.1.4. Yakın kızılötesi bant reflektans değerleri

Yakın Kızılötesi (NIR) bant, özellikle bitki örtüsü yoğun alanların ayrımında önemli bir rol oynar. Bitki örtüsü yoğun alanlar bu bantta yüksek yansıma değerleri sergilerken, su veya koyu renkli yüzeylerden nispeten düşük değerler elde edilebilir. Kıyı sınıflarının NIR bant yansıma değerleri, yüzey özelliklerini detaylı bir şekilde incelemek için analiz edilmiştir. Tanımlayıcı istatistikler Tablo 5'te sunulmuştur. Haliç Tipi Kıyılar, 2,702 ortalama yansıma değeriyle en yüksek yansımayı gösterirken, Volkanik Kıyılar 1,835 ortalama ile en düşük yansıma değerine sahiptir. Mercan Resifleri (1,113 standart sapma) ve Buzul Kıyıları (1,429 standart sapma) geniş yansıma aralıkları göstermiştir.

Tablo 5. Yakın kızılötesi bant için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	2.660	505	1.206	2.371	2.674	2.949	4.829
Antropojenik Kıyılar	1.250	2.322	433	884	2.006	2.275	2.568	3.998
Kayalık Kıyılar	1.250	2.388	511	645	2.107	2.357	2.649	4.430
Haliç Tipi Kıyılar	1.250	2.702	702	456	2.251	2.649	3.163	4.863
Volkanik Kıyılar	1.250	1.835	763	139	1.391	1.876	2.378	3.848
Mercan Resifleri	1.250	2.358	1.113	12	1.425	2.575	3.155	5.193
Buzul Kıyıları	1.250	2.272	1.429	120	1.228	2.044	2.498	9.435

NIR bant yansıma değerlerinin dağılımı, sınıfların spektral özelliklerini görselleştirmek için Şekil 16'te violin grafiği ile sunulmuştur. Grafik, Haliç Tipi Kıyılar'ın yüksek yansıma değerlerini ve Volkanik Kıyılar'ın düşük değerlerini açıkça göstermektedir.

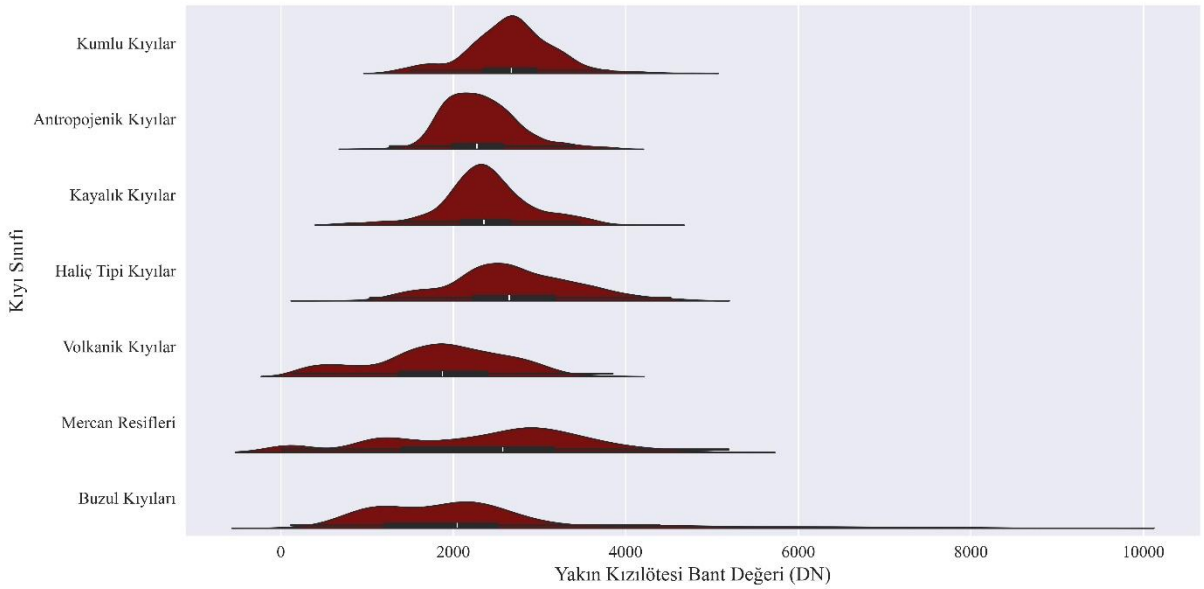

Şekil 16. Yakın kızılötesi bant için kıyı tiplerinin spektral değer dağılımı (violin grafiği).

3.2. Dokusal Analiz Bulguları

Dokusal analizde, kıyı sınıflarının yüzey desenleri Gri Seviye Eş-oluşum Matrisi (GLCM) tabanlı ölçütler kullanılarak karakterize edilmiştir. Kontrast, benzeşmezlik, homojenlik, enerji ve korelasyon ölçütleri, sınıfların mekansal düzenlerini ve yüzey karmaşıklığını ortaya koymayı amaçlamıştır. Her ölçüt için tanımlayıcı istatistikler hesaplanmış, dağılımlar kutu grafikleriyle görselleştirilmiştir. Aşağıda, her ölçüt için sonuçlar, sınıfların yüzey desenlerindeki farklılıkları öne çıkaracak şekilde sunulmaktadır.

3.2.1. Kontrast ölçütü

Kontrast ölçütü, piksel yoğunluklarındaki yerel varyasyonları ölçerek yüzey desenlerinin karmaşıklığını ifade eder. Yüksek kontrast değerleri heterojen yüzeyleri, düşük değerler ise daha düzgün yüzeyleri gösterir. Kıyı sınıflarının kontrast değerleri, 1,250 görüntülük veri seti üzerinden analiz edilmiştir. Tanımlayıcı istatistikler Tablo 6'te sunulmuştur. Antropojenik Kıyılar (ortalama kontrast: 308,13) en yüksek karmaşıklığı sergilerken, Kayalık Kıyılar (ortalama kontrast: 183,10) en düşük karmaşıklığa sahiptir. Mercan Resifleri (standart sapma: 272,27) geniş bir varyasyon göstermiştir.

Tablo 6. Kontrast ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	259,26	138,79	17,48	150,64	244,10	353,00	808,23
Antropojenik Kıyılar	1.250	308,13	171,14	40,02	201,83	274,02	374,29	1.542,22
Kayalık Kıyılar	1.250	183,10	89,54	13,39	120,35	168,04	228,24	664,97
Haliç Tipi Kıyılar	1.250	292,16	165,99	16,71	177,27	260,55	368,09	1.435,98
Volkanik Kıyılar	1.250	186,89	83,09	12,11	125,54	176,86	232,09	566,27
Mercan Resifleri	1.250	266,91	272,27	8,62	104,97	187,36	310,44	2.011,15
Buzul Kıyıları	1.250	238,56	133,10	12,74	147,16	214,76	292,20	1.116,41

Kontrast değerlerinin dağılımı, sınıfların yüzey karmaşıklığını görselleştirmek için Şekil 17'te kutu grafiği ile sunulmuştur. Grafik, Antropojenik Kıyılar'ın yüksek kontrast değerlerini ve Kayalık Kıyılar'ın düşük değerlerini açıkça ortaya koymaktadır.

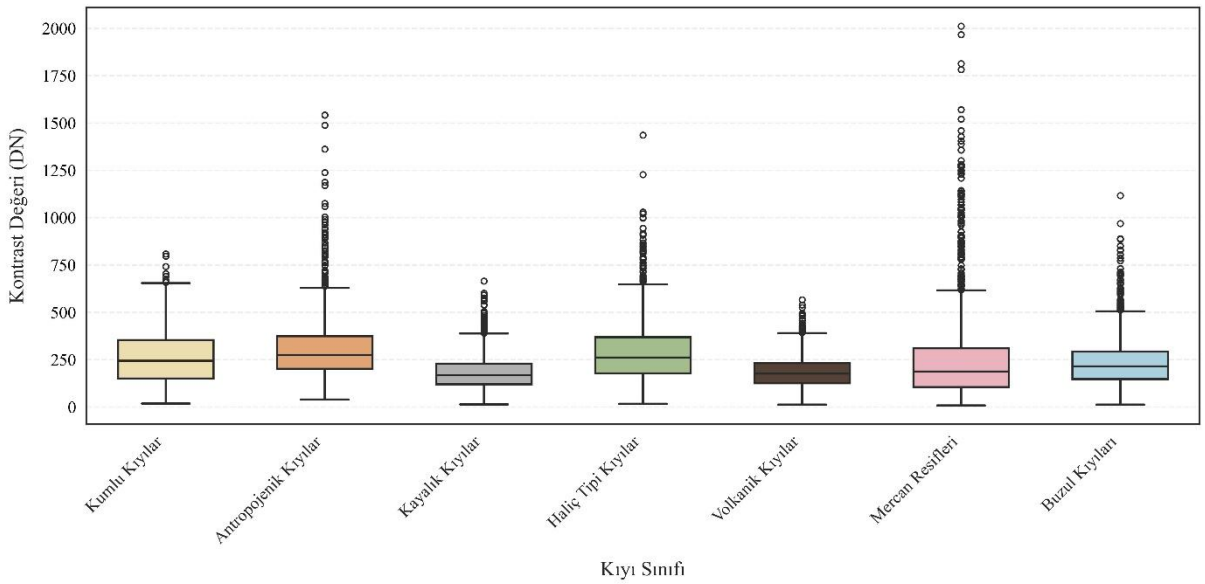

Şekil 17. Kıyı sınıfları için hesaplanan kontrast değerleri (kutu grafiği).

3.2.2. Benzeşmezlik ölçütü

Benzeşmezlik ölçütü, piksel çiftleri arasındaki yoğunluk farklarını ölçerek yüzey desenlerinin yerel varyasyonunu ifade eder. Yüksek benzeşmezlik değerleri, daha karmaşık yüzeyleri gösterir. Kıyı sınıflarının benzeşmezlik değerleri analiz edilmiş ve tanımlayıcı istatistikler Tablo 7'da sunulmuştur. Haliç Tipi Kıyılar (ortalama benzeşmezlik: 9,86) en yüksek varyasyonu sergilerken, Volkanik Kıyılar (ortalama benzeşmezlik: 6,92) en düşük varyasyona sahiptir. Mercan Resifleri (standart sapma: 5,71) geniş bir dağılım göstermiştir.

Tablo 7. Benzeşmezlik ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	8,92	2,72	2,26	6,85	8,83	10,78	17,76
Antropojenik Kıyılar	1.250	9,60	2,99	2,53	7,59	9,27	11,19	29,44
Kayalık Kıyılar	1.250	7,09	2,05	2,10	5,74	6,89	8,22	17,69
Haliç Tipi Kıyılar	1.250	9,86	3,14	1,51	7,67	9,43	11,45	25,19
Volkanik Kıyılar	1.250	6,92	1,97	1,88	5,55	6,96	8,21	17,11
Mercan Resifleri	1.250	8,58	5,71	0,43	5,24	6,93	9,57	35,51
Buzul Kıyıları	1.250	8,03	2,87	1,49	6,11	7,74	9,47	22,55

Benzeşmezlik değerlerinin dağılımı, sınıfların yüzey varyasyonlarını görselleştirmek için Şekil 18'de kutu grafiği ile sunulmuştur. Grafik, Haliç Tipi Kıyılar'ın yüksek benzeşmezlik değerlerini ve Volkanik Kıyılar'ın düşük değerlerini öne çıkarmaktadır.

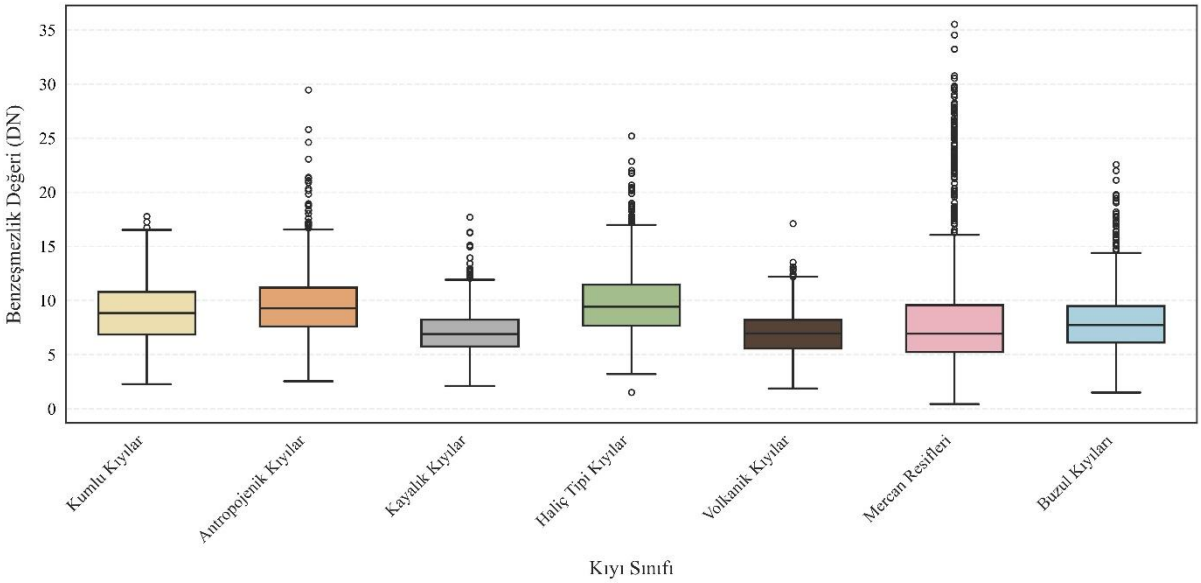

Şekil 18. Kıyı sınıfları için hesaplanan benzeşmezlik değerleri (kutu grafiği).

3.2.3. Homojenlik ölçütü

Homojenlik ölçütü, piksel yoğunluklarının benzerliğini ölçerek yüzey desenlerinin düzgünlüğünü ifade eder. Yüksek homojenlik değerleri, daha düzgün yüzeyleri gösterir. Kıyı sınıflarının homojenlik değerleri analiz edilmiş ve tanımlayıcı istatistikler Tablo 8'de sunulmuştur. Buzul Kıyıları (ortalama homojenlik: 0,41) en düzgün yüzeyleri sergilerken, Haliç Tipi Kıyılar (ortalama homojenlik: 0,25) en düşük homojenliğe sahiptir. Mercan Resifleri (standart sapma: 0,15) geniş bir varyasyon göstermiştir.

Tablo 8. Homojenlik ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	0,31	0,08	0,11	0,26	0,31	0,37	0,56
Antropojenik Kıyılar	1.250	0,34	0,09	0,08	0,28	0,35	0,41	0,61
Kayalık Kıyılar	1.250	0,36	0,08	0,14	0,30	0,36	0,42	0,60
Haliç Tipi Kıyılar	1.250	0,25	0,11	0,06	0,15	0,25	0,32	0,62
Volkanik Kıyılar	1.250	0,37	0,09	0,07	0,32	0,38	0,44	0,74
Mercan Resifleri	1.250	0,31	0,15	0,04	0,21	0,32	0,41	1,00
Buzul Kıyıları	1.250	0,41	0,12	0,07	0,36	0,43	0,48	0,75

Homojenlik değerlerinin dağılımı, sınıfların yüzey düzgünlüğünü görselleştirmek için Şekil 19'da kutu grafiği ile sunulmuştur. Grafik, Buzul Kıyıları'nın yüksek homojenlik değerlerini ve Haliç Tipi Kıyılar'ın düşük değerlerini açıkça göstermektedir.

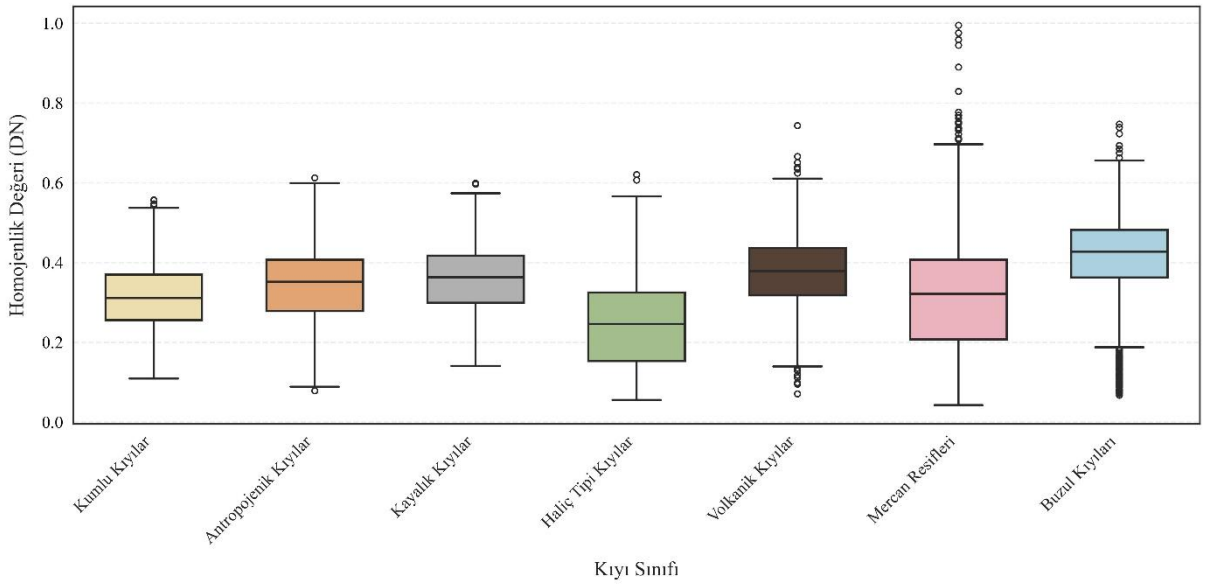

Şekil 19. Kıyı sınıfları için hesaplanan homojenlik değerleri (kutu grafiği).

3.2.4. Enerji ölçütü

Enerji ölçütü, piksel yoğunluklarının düzenli dağılımını ölçerek yüzey desenlerinin tekdüzeliğini ifade eder. Yüksek enerji değerleri, daha düzenli yüzeyleri gösterir. Kıyı sınıflarının enerji değerleri analiz edilmiş ve tanımlayıcı istatistikler Tablo 9'da sunulmuştur. Buzul Kıyıları (ortalama enerji: 0,21) en düzenli yüzeyleri sergilerken, Haliç Tipi Kıyılar (ortalama enerji: 0,06) en düşük tekdüzeliğe sahiptir. Mercan Resifleri, 0,98 maksimum değeriyle aykırı bir değer göstermiştir.

Tablo 9. Enerji ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	0,10	0,06	0,02	0,06	0,09	0,14	0,30
Antropojenik Kıyılar	1.250	0,12	0,07	0,02	0,06	0,11	0,17	0,35
Kayalık Kıyılar	1.250	0,13	0,07	0,02	0,08	0,12	0,17	0,50
Haliç Tipi Kıyılar	1.250	0,06	0,05	0,01	0,02	0,04	0,08	0,29
Mercan Resifleri	1.250	0,09	0,10	0,01	0,04	0,06	0,11	0,98
Volkanik Kıyılar	1.250	0,15	0,10	0,02	0,07	0,13	0,19	0,51
Buzul Kıyıları	1.250	0,21	0,12	0,01	0,14	0,20	0,28	0,69

Enerji değerlerinin dağılımı, sınıfların yüzey tekdüzeliğini görselleştirmek için Şekil 20'de kutu grafiği ile sunulmuştur. Grafik, Buzul Kıyıları'nın yüksek enerji değerlerini ve Haliç Tipi Kıyılar'ın düşük değerlerini vurgulamaktadır.

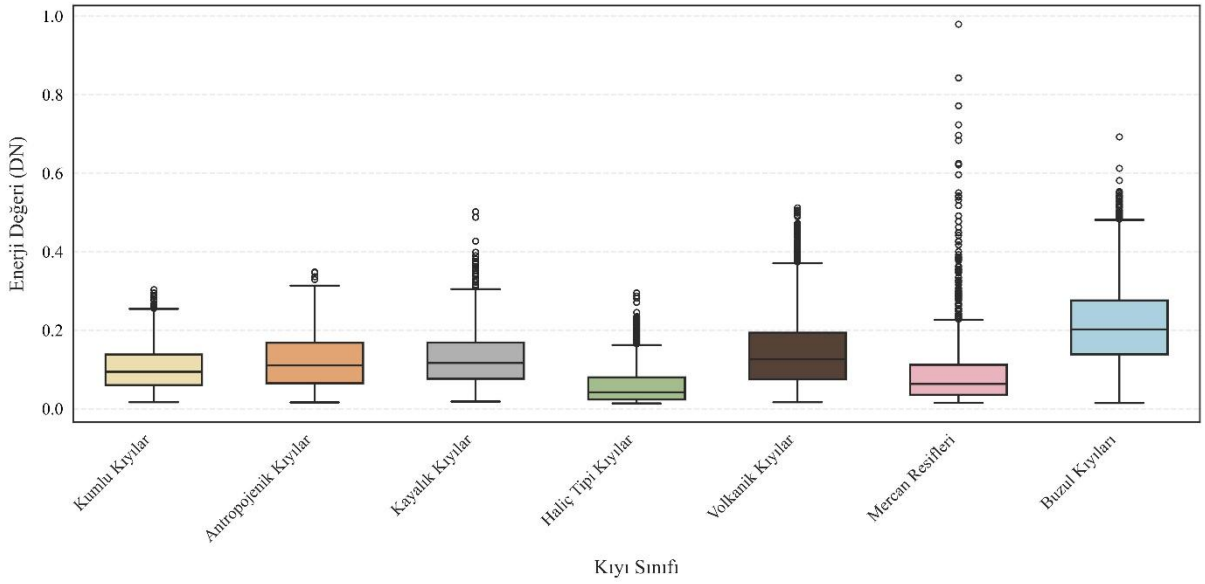

Şekil 20. Kıyı sınıfları için hesaplanan enerji değerleri (kutu grafiği).

3.2.5. Korelasyon ölçütü

Korelasyon ölçütü, piksel yoğunlukları arasındaki doğrusal ilişkiyi ölçerek yüzey desenlerinin düzenliliğini ifade eder. Yüksek korelasyon değerleri, daha düzenli yüzeyleri gösterir. Kıyı sınıflarının korelasyon değerleri analiz edilmiş ve tanımlayıcı istatistikler Tablo 10'da sunulmuştur. Kayalık Kıyılar (ortalama korelasyon: 0,98) en düzenli yüzeyleri sergilerken, Mercan Resifleri (ortalama korelasyon: 0,93) en düşük düzenliliğe sahiptir. Mercan Resifleri (standart sapma: 0,13) geniş bir varyasyon göstermiştir.

Tablo 10. Korelasyon ölçütü için kıyı sınıflarına ait tanımlayıcı istatistikler.

Kıyı Sınıfı	Görüntü Sayısı	Ort.	Standart Sapma	Min.	%25	%50	%75	Maks.
Kumlu Kıyılar	1.250	0,97	0,02	0,86	0,97	0,98	0,99	1,00
Antropojenik Kıyılar	1.250	0,94	0,04	0,66	0,93	0,95	0,97	1,00
Kayalık Kıyılar	1.250	0,98	0,02	0,89	0,97	0,98	0,99	1,00
Haliç Tipi Kıyılar	1.250	0,96	0,04	0,65	0,95	0,97	0,98	1,00
Volkanik Kıyılar	1.250	0,96	0,04	0,60	0,96	0,97	0,98	1,00
Mercan Resifleri	1.250	0,93	0,13	0,28	0,95	0,98	0,99	1,00
Buzul Kıyıları	1.250	0,97	0,03	0,72	0,96	0,97	0,98	1,00

Korelasyon değerlerinin dağılımı, sınıfların yüzey düzenliliğini görselleştirmek için Şekil 21'da kutu grafiği ile sunulmuştur. Grafik, Kayalık Kıyılar'ın yüksek korelasyon değerlerini ve Mercan Resifleri'nin geniş varyasyonunu açıkça göstermektedir.

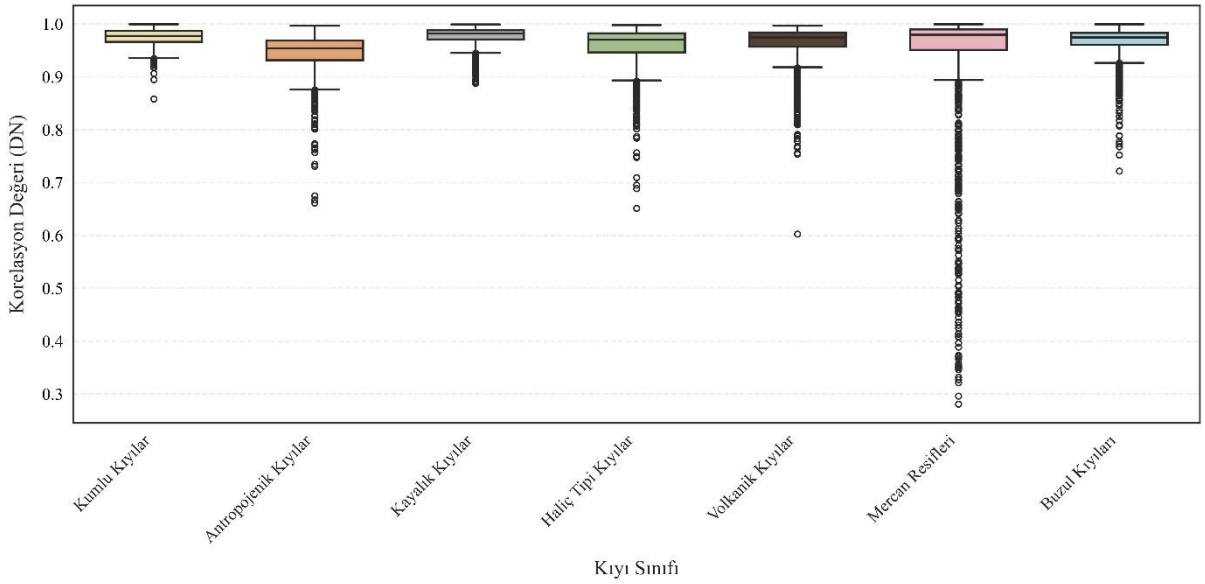

Şekil 21. Kıyı sınıfları için hesaplanan korelasyon değerleri (kutu grafiği).

3.3. Model Performansı Bulguları

VGG-16 modelinin sınıflandırma performansı, dört bant kombinasyonu (R-G-B, NIR-G-B, NIR-R-G, NIR-R-B) için hem sıfırdan başlatılan ağırlıklarla hem de transfer öğrenimi kullanılarak değerlendirilmiştir. Bu analiz, modelin kıyı sınıflarını ayırt etme yeteneğini ölçmeyi ve farklı bant kombinasyonlarının performans üzerindeki etkisini incelemeyi amaçlamıştır. Model performansı, genel doğruluk oranları, ROC eğrileri ve karışıklık matrisleri kullanılarak analiz edilmiştir. Modelin eğitim ve doğrulama süreçlerine dair detaylı bilgi Ek-1'de sunulmuştur.

3.3.1. Genel doğruluk değerleri

Modelin genel doğruluk oranları, her bir bant kombinasyonu için hem standart hem de transfer öğrenimi ile elde edilen ağırlıklar kullanılarak hesaplanmıştır. Şekil 22, dört bant kombinasyonunun doğruluk oranlarını göstermektedir. Transfer öğrenimi, tüm bant kombinasyonlarında sıfırdan başlatılan ağırlıklara göre daha yüksek doğruluk oranları elde edilmesini sağlamıştır. Transfer öğrenimi uygulandığında, NIR-G-B kombinasyonu %96,97 doğruluk oranıyla en yüksek performansı sergilerken, R-G-B kombinasyonu %96,63 doğruluk oranıyla yakın bir başarı göstermiştir. NIR-R-G ve NIR-R-B kombinasyonları ise sırasıyla %95,89 ve %95,94 doğruluk oranlarına ulaşmıştır. Sıfırdan başlatılan ağırlıklarla yapılan

analizlerde, NIR-R-B kombinasyonu %83,89 doğruluk oranıyla en yüksek performansı göstermiş, bunu %77,20 doğruluk oranıyla NIR-R-G kombinasyonu izlemiştir.

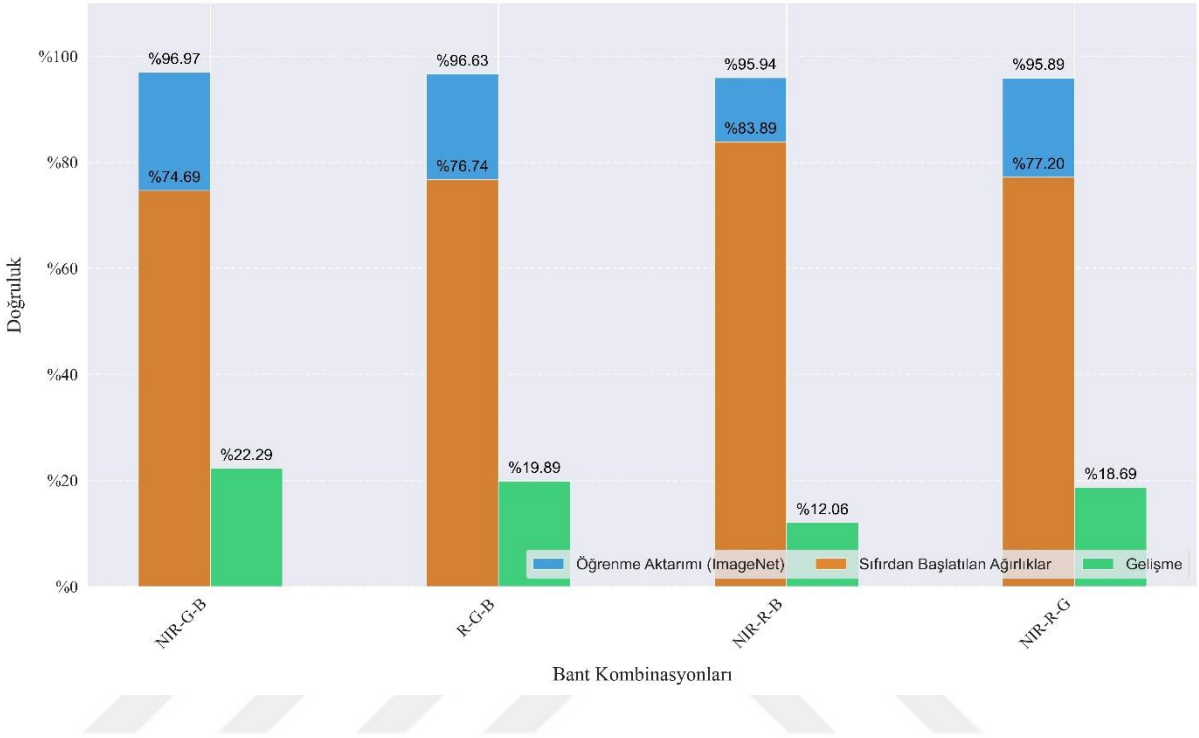

Şekil 22. Denemeler neticesinde elde edilen genel isabetlilik yüzdeleri.

3.3.2. ROC eğrileri

ROC eğrileri, modelin her bir sınıf için sınıflandırma performansını değerlendirmek amacıyla kullanılmıştır. Yanlış pozitif oranı ile doğru pozitif oranı arasındaki ilişkiyi gösteren bu eğriler, sınıfların ayrıştırılma başarısını AUC (eğri altındaki alan) değerleriyle ölçer. Aşağıda, her sınıf için ROC eğrileri, ilgili bant kombinasyonlarının AUC değerleri ve standart/transfer öğrenimi karşılaştırmalarıyla sunulmaktadır.

Kumlu Kıyılar'ın ROC eğrileri, modelin bu sınıfı diğerlerinden ayırma başarısını değerlendirmiştir. Sıfırdan başlatılan ağırlıklarla, AUC değerleri R-G-B için 0,969, NIR-G-B için 0,970, NIR-R-G için 0,966 ve NIR-R-B için 0,988 olarak hesaplanmıştır. NIR-R-B kombinasyonu, sıfırdan başlatılan ağırlıklar arasında en yüksek ayrıştırılma başarısını göstermiştir. Transfer öğrenimiyle, AUC değerleri tüm kombinasyonlarda 0,999'a yükselmiş, özellikle NIR-G-B ve NIR-R-G kombinasyonlarında mükemmele yakın bir performans

sergilenmiştir. Şekil 23, bu eğrileri görselleştirerek transfer öğreniminin sağladığı iyileşmeyi açıkça ortaya koymaktadır.

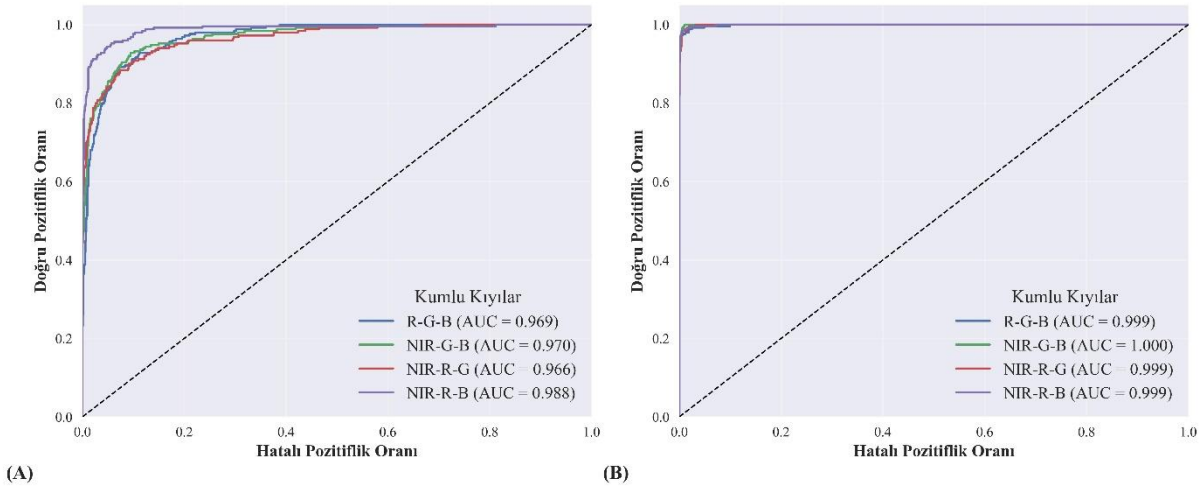

Şekil 23. Kumlu kıyılar için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Antropojenik Kıyılar, modelin en yüksek ayrıştırılma başarısını sergilediği sınıflardan biridir. Standart ağırlıklarla, AUC değerleri R-G-B için 0,964, NIR-G-B için 0,966, NIR-R-G için 0,970 ve NIR-R-B için 0,989 olarak hesaplanmıştır. NIR-R-B kombinasyonu, standart ağırlıklar arasında en yüksek performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri tüm kombinasyonlarda 0,999-1,000 aralığına ulaşmış, özellikle NIR-G-B ve NIR-R-B kombinasyonlarında mükemmel ayrıştırılma sağlanmıştır. Şekil 24, bu eğrileri görselleştirerek transfer öğreniminin etkisini vurgulamaktadır.

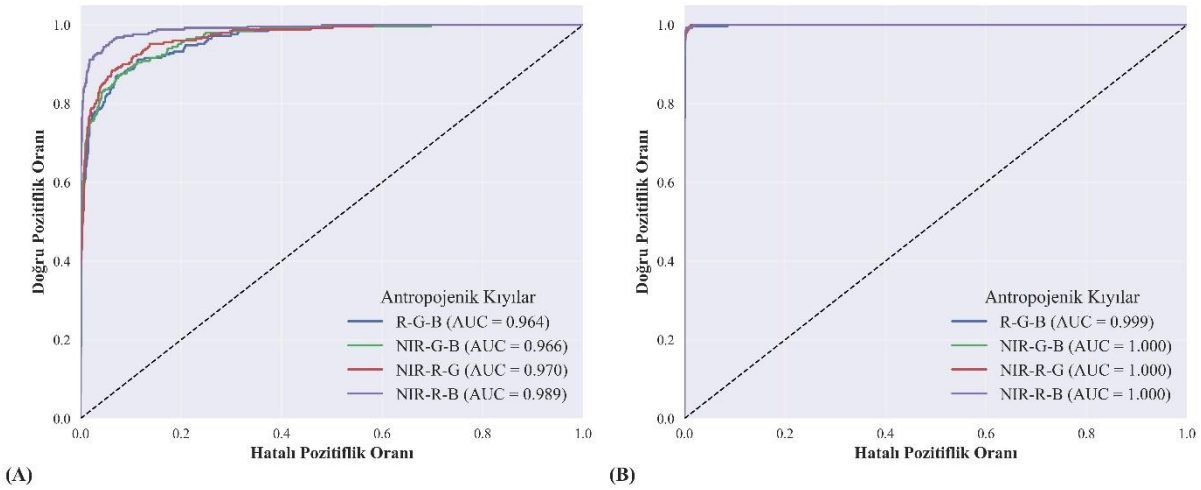

Şekil 24. Antropojenik kıyılar için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Kayalık Kıyılar, standart ağırlıklarla en düşük ayrıştırılma başarısını sergileyen sınıftır. AUC değerleri R-G-B için 0,904, NIR-G-B için 0,885, NIR-R-G için 0,890 ve NIR-R-B için 0,923 olarak hesaplanmıştır. NIR-G-B kombinasyonu, standart ağırlıklar arasında en düşük performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri R-G-B için 0,997, NIR-G-B için 0,995, NIR-R-G için 0,992 ve NIR-R-B için 0,990'a yükselmiş, özellikle R-G-B kombinasyonunda belirgin bir iyileşme sağlanmıştır. Şekil 25, bu eğrileri görselleştirerek transfer öğreniminin Kayalık Kıyılar için ayrıştırılma başarısını artırdığını göstermektedir.

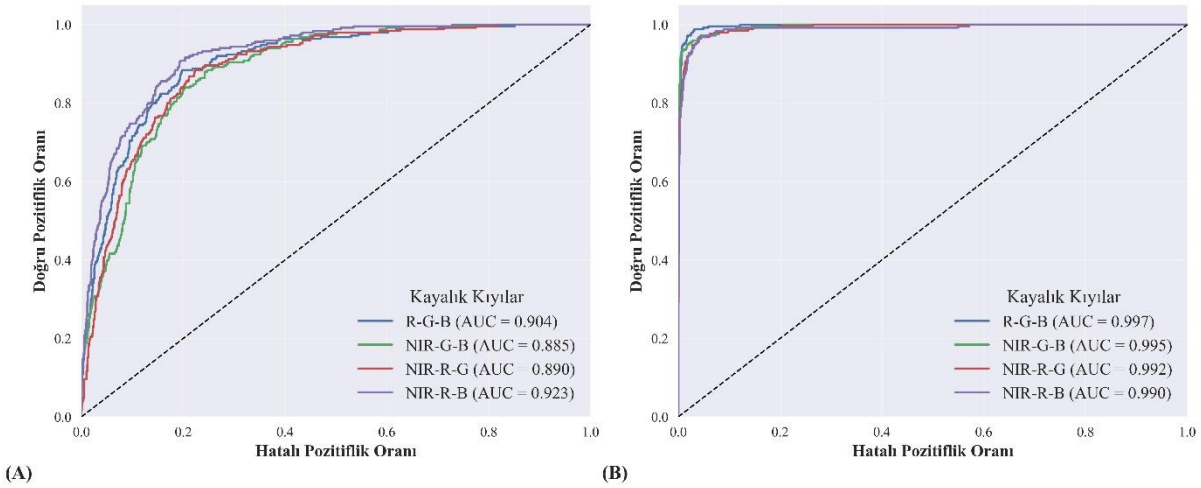

Şekil 25. Kayalık kıyılar için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Haliç Tipi Kıyılar, yüksek ayrıştırılma başarısı sergileyen sınıflardan biridir. Standart ağırlıklarla, AUC değerleri R-G-B için 0,979, NIR-G-B için 0,985, NIR-R-G için 0,983 ve NIR-R-B için 0,989 olarak hesaplanmıştır. NIR-R-B kombinasyonu, standart ağırlıklar arasında en yüksek performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri R-G-B için 0,996, NIR-G-B için 0,998, NIR-R-G için 0,998 ve NIR-R-B için 0,999'a yükselmiş, özellikle NIR-R-B kombinasyonunda neredeyse mükemmel bir ayrıştırılma sağlanmıştır. Şekil 26, bu eğrileri görselleştirerek transfer öğreniminin katkısını açıkça ortaya koymaktadır.

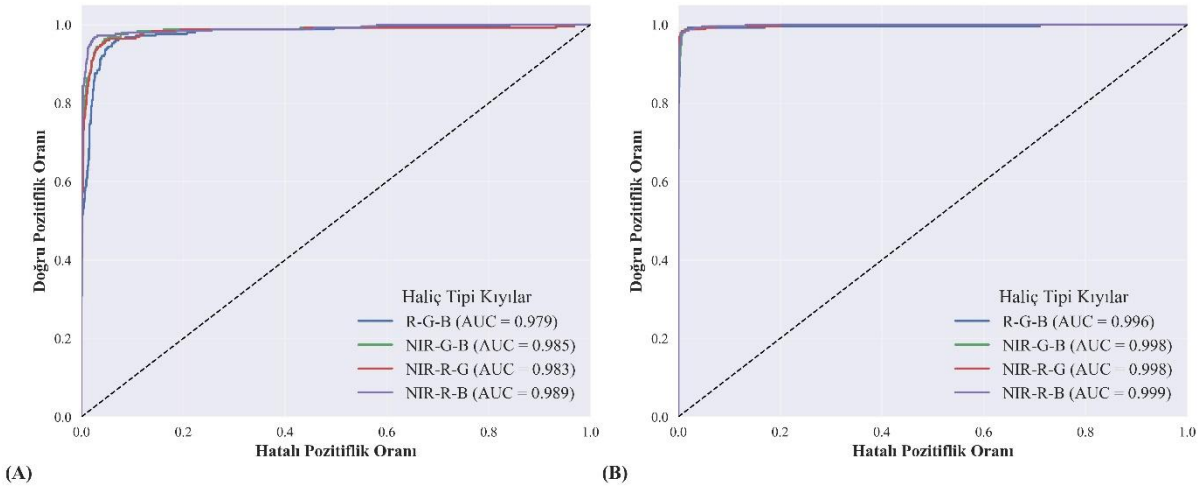

Şekil 26. Haliç tipi kıyılar için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Volkanik Kıyılar'ın ROC eğrileri, modelin bu sınıfı ayırma başarısını değerlendirmiştir. Standart ağırlıklarla, AUC değerleri R-G-B için 0,970, NIR-G-B için 0,962, NIR-R-G için 0,950 ve NIR-R-B için 0,969 olarak hesaplanmıştır. NIR-R-G kombinasyonu, standart ağırlıklar arasında en düşük performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri R-G-B için 0,997, NIR-G-B için 0,998, NIR-R-G için 0,995 ve NIR-R-B için 0,995'e yükselmiş, özellikle NIR-G-B kombinasyonunda yüksek bir iyileşme sağlanmıştır. Şekil 27, bu eğrileri görselleştirerek transfer öğreniminin etkisini vurgulamaktadır.

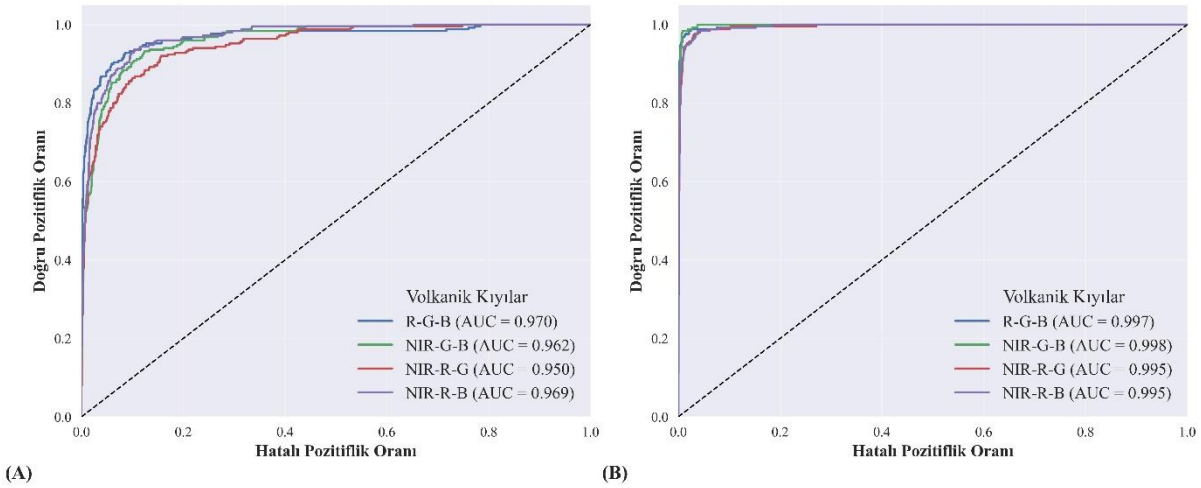

Şekil 27. Volkanik kıyılar için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Mercan Resifleri, modelin yüksek ayrıştırılma başarısı sergilediği sınıflardan biridir. Standart ağırlıklarla, AUC değerleri R-G-B için 0,973, NIR-G-B için 0,982, NIR-R-G için 0,984 ve NIR-R-B için 0,993 olarak hesaplanmıştır. NIR-R-B kombinasyonu, standart ağırlıklar arasında en yüksek performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri R-G-B için 0,999, NIR-G-B için 1,000, NIR-R-G için 1,000 ve NIR-R-B için 0,999'a yükselmiş, özellikle NIR-G-B ve NIR-R-G kombinasyonlarında mükemmel ayrıştırılma sağlanmıştır. Şekil 28, bu eğrileri görselleştirerek transfer öğreniminin katkısını açıkça ortaya koymaktadır.

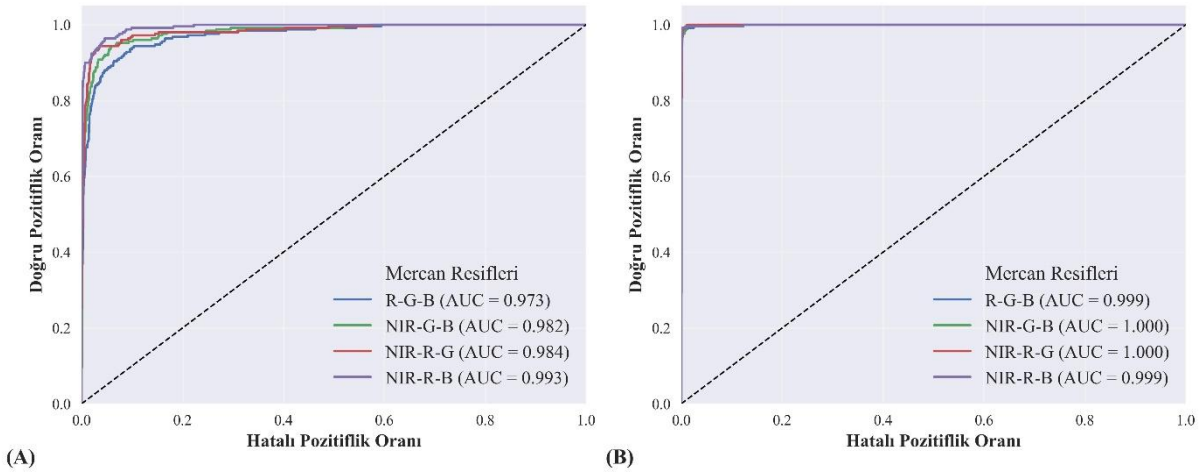

Şekil 28. Mercan resifleri için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

Buzul Kıyıları'nın ROC eğrileri, modelin bu sınıfı ayırma başarısını değerlendirmiştir. Standart ağırlıklarla, AUC değerleri R-G-B için 0,955, NIR-G-B için 0,941, NIR-R-G için 0,945 ve NIR-R-B için 0,976 olarak hesaplanmıştır. NIR-G-B kombinasyonu, standart ağırlıklar arasında en düşük performansı göstermiştir. Transfer öğrenimiyle, AUC değerleri R-G-B için 0,995, NIR-G-B için 0,998, NIR-R-G için 0,997 ve NIR-R-B için 0,997'e yükselmiş, özellikle NIR-G-B kombinasyonunda belirgin bir iyileşme sağlanmıştır. Şekil 29, bu eğrileri görselleştirerek transfer öğreniminin Buzul Kıyıları için ayrıştırılma başarısını artırdığını göstermektedir.

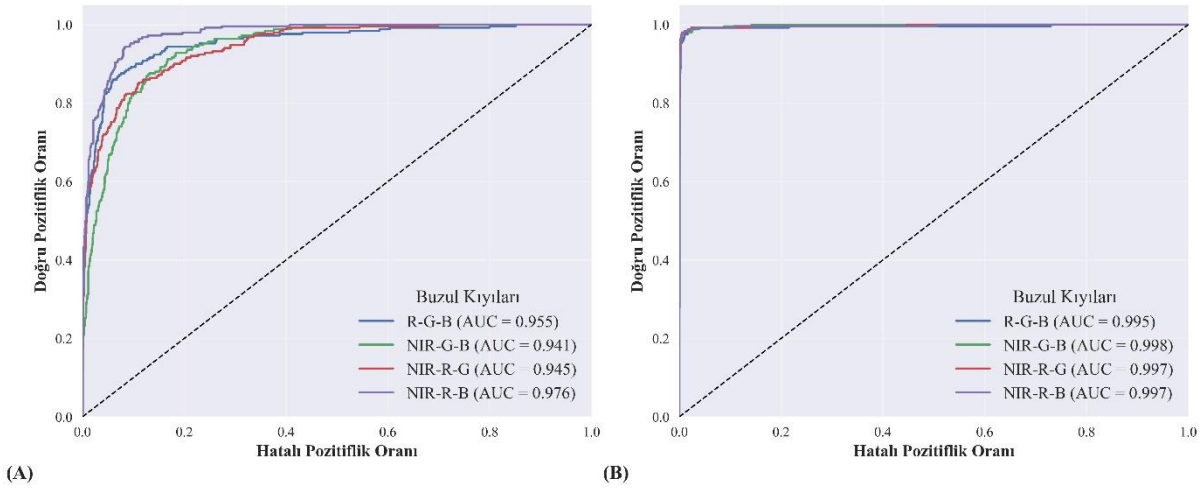

Şekil 29. Buzul kıyıları için ROC eğrileri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar.

3.3.3. Karışıklık matrisleri

Karışıklık matrisleri, modelin sınıflandırma performansını sınıflar arasındaki karışıklık oranlarıyla değerlendirmek için kullanılmıştır. Her bant kombinasyonu için normalize edilmiş karışıklık matrisleri, doğru sınıflandırma oranlarını ve karışıklık eğilimlerini ortaya koymaktadır. Aşağıda, her bant kombinasyonu için karışıklık matrisleri, doğruluk oranları ve karışıklık eğilimleriyle detaylandırılmıştır.

Tüm bant kombinasyonlarının ortalama karışıklık matrisleri, modelin genel sınıflandırma performansını özetlemektedir. Standart ağırlıklarla, Haliç Tipi Kıyılar (%92,1), Antropojenik Kıyılar (%84,4) ve Kumlu Kıyılar (%84,8) yüksek doğruluk oranlarıyla öne çıkarken, Kayalık Kıyılar %51,9 ile en düşük performansı sergilemiş, sıklıkla Buzul Kıyıları (%10,9) ve Volkanik Kıyılar (%14,0) ile karıştırılmıştır. Transfer öğrenimiyle, doğruluk oranları tüm sınıflarda artmış; Antropojenik Kıyılar %98,8, Kumlu Kıyılar %96,7 ve Haliç Tipi Kıyılar %96,7 doğruluk oranlarına ulaşmıştır. Kayalık Kıyılar'ın doğruluk oranı %91,8'e yükselmiş, Buzul Kıyılar ile karışıklık oranı %2,4'e düşmüştür. Şekil 30, bu matrisleri görselleştirerek transfer öğreniminin karışıklık oranlarını azalttığını göstermektedir.

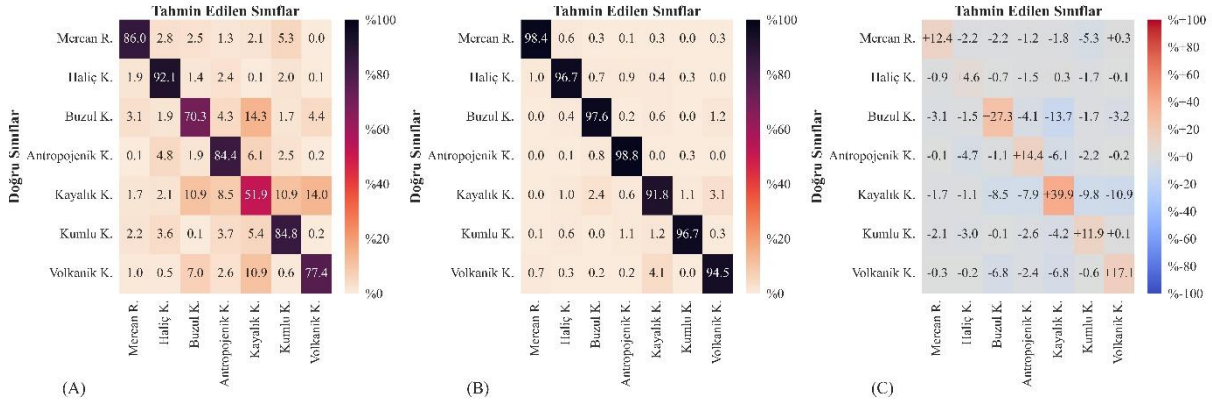

Şekil 30. Tüm bant kombinasyonlarına göre karışıklık matrisleri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar, (C) değişimler.

NIR-G-B kombinasyonu, transfer öğrenimiyle en yüksek genel doğruluk oranını (%96,97) sağlamıştır. Standart ağırlıklarla, Haliç Tipi Kıyılar %94,0, Kumlu Kıyılar %85,2 ve Antropojenik Kıyılar %81,6 doğruluk oranlarıyla yüksek performans gösterirken, Kayalık Kıyılar %43,6 ile en düşük doğruluğu sergilemiş, özellikle Volkanik Kıyılar (%16,4) ve Buzul Kıyıları (%12,4) ile karıştırılmıştır. Transfer öğrenimiyle, Antropojenik Kıyılar %98,8, Haliç Tipi Kıyılar %97,2 ve Kumlu Kıyılar %97,2 doğruluk oranlarına ulaşmış; Kayalık Kıyılar'ın doğruluğu %93,2'ye yükselmiş, Volkanik Kıyılar ile karışıklık oranı %2,0'a düşmüştür. Şekil 31, bu matrisleri görselleştirerek NIR-G-B kombinasyonunun transfer öğrenimiyle sağladığı iyileşmeyi ortaya koymaktadır.

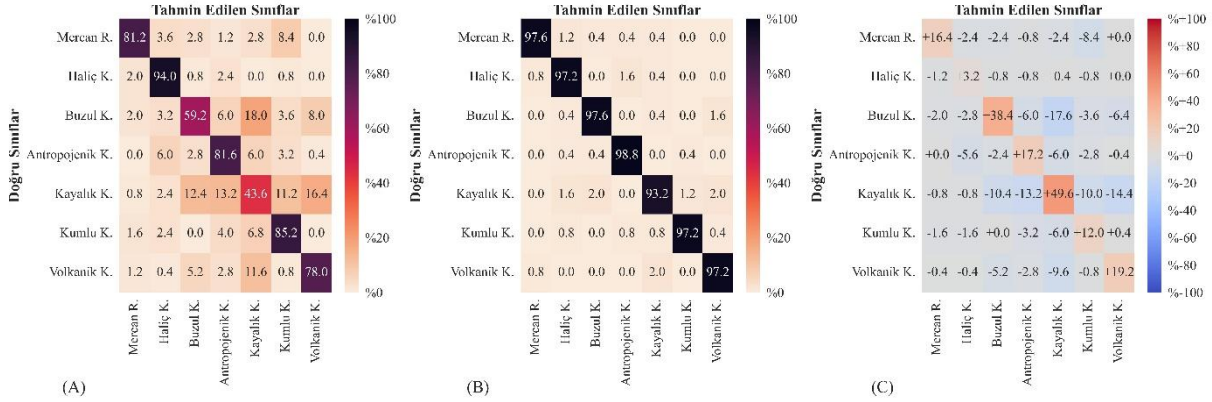

Şekil 31. NIR-G-B bant kombinasyonu için karışıklık matrisleri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar, (C) değişimler.

NIR-R-B kombinasyonu, standart ağırlıklarla en yüksek genel doğruluk oranını (%83,89) sağlamıştır. Standart ağırlıklarla, Haliç Tipi Kıyılar %94,8, Antropojenik Kıyılar %90,4 ve Kumlu Kıyılar %89,2 yüksek doğruluk oranları sergilerken, Kayalık Kıyılar %61,2 ile düşük performans göstermiş, özellikle Buzul Kıyıları (%14,0) ve Volkanik Kıyılar (%13,2) ile karıştırılmıştır. Transfer öğrenimiyle, Antropojenik Kıyılar %99,2, Haliç Tipi Kıyılar %97,6 ve Kumlu Kıyılar %96,8 doğruluk oranlarına ulaşmış; Kayalık Kıyılar'ın doğruluğu %89,2'ye yükselmiş, Volkanik Kıyılar ile karışıklık oranı %5,2'ye düşmüştür. Şekil 32, bu matrisleri görselleştirerek NIR-R-B kombinasyonunun performansını detaylandırmaktadır.

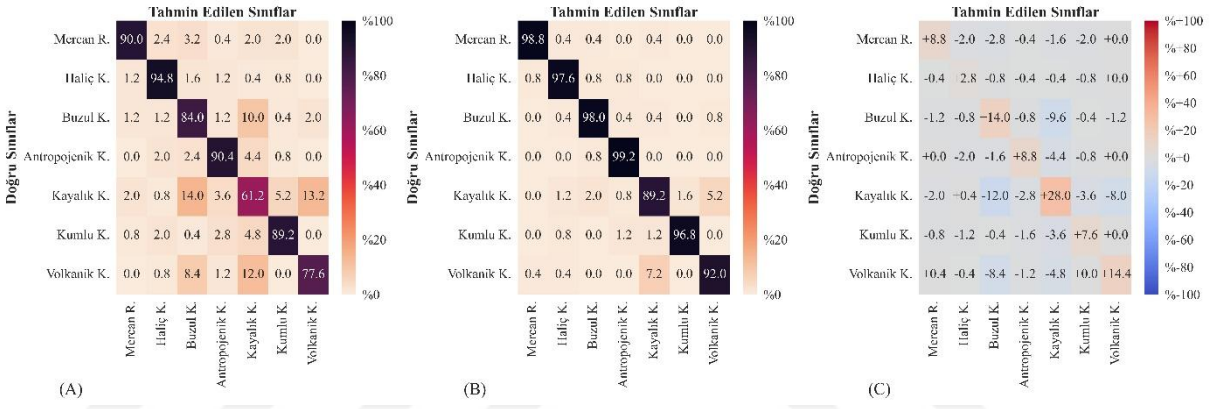

Şekil 32. NIR-R-B bant kombinasyonu için karışıklık matrisleri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar, (C) değişimler.

NIR-R-G kombinasyonu, standart ağırlıklarla %80,07 doğruluk oranı sağlamıştır. Standart ağırlıklarla, Haliç Tipi Kıyılar %91,6, Antropojenik Kıyılar %84,4 ve Mercan Resifleri %89,2 yüksek doğruluk oranları sergilerken, Kayalık Kıyılar %52,4 ile düşük performans göstermiş, özellikle Volkanik Kıyılar (%16,0) ve Kumlu Kıyılar (%10,0) ile karıştırılmıştır. Transfer öğrenimiyle, Mercan Resifleri %98,8, Antropojenik Kıyılar %98,4 ve Kumlu Kıyılar %97,2 doğruluk oranlarına ulaşmış; Kayalık Kıyılar'ın doğruluğu %89,6'ya yükselmiş, Volkanik Kıyılar ile karışıklık oranı %4,0'a düşmüştür. Şekil 33, bu matrisleri görselleştirerek NIR-R-G kombinasyonunun transfer öğrenimiyle sağladığı iyileşmeyi göstermektedir.

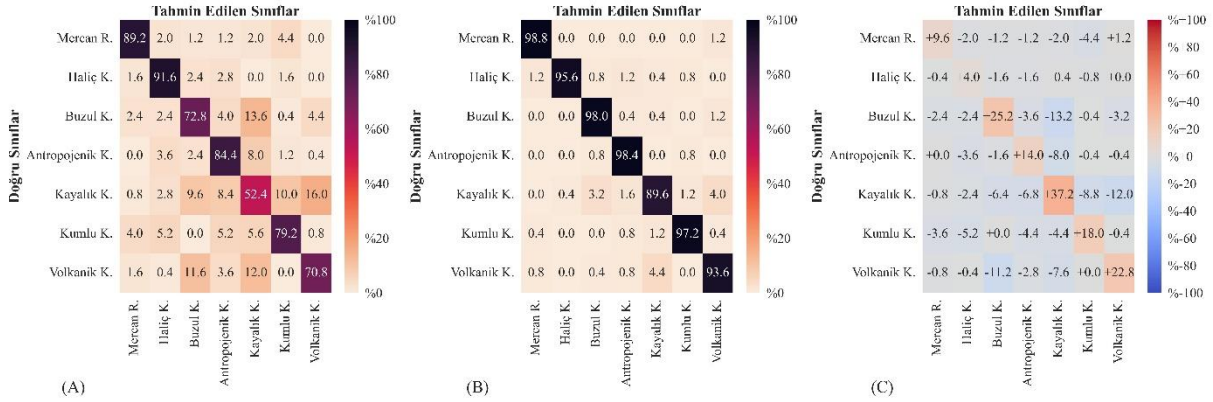

Şekil 33. NIR-R-G kombinasyonu için karışıklık matrisleri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar, (C) değişimler.

R-G-B kombinasyonu, transfer öğrenimiyle %96,63 doğruluk oranı sağlamıştır. Standart ağırlıklarla, Haliç Tipi Kıyılar %88,0, Kumlu Kıyılar %85,6 ve Antropojenik Kıyılar %81,2 yüksek doğruluk oranları sergilerken, Kayalık Kıyılar %50,4 ile en düşük performansı göstermiş, özellikle Kumlu Kıyılar (%17,2) ve Volkanik Kıyılar (%10,4) ile karıştırılmıştır. Transfer öğrenimiyle, Antropojenik Kıyılar %98,8, Kumlu Kıyılar %95,6 ve Haliç Tipi Kıyılar %96,4 doğruluk oranlarına ulaşmış; Kayalık Kıyılar'ın doğruluğu %95,2'ye yükselmiş, Kumlu Kıyılar ile karışıklık oranı %0,4'e düşmüştür. Şekil 34, bu matrisleri görselleştirerek R-G-B kombinasyonunun performansını detaylandırmaktadır.

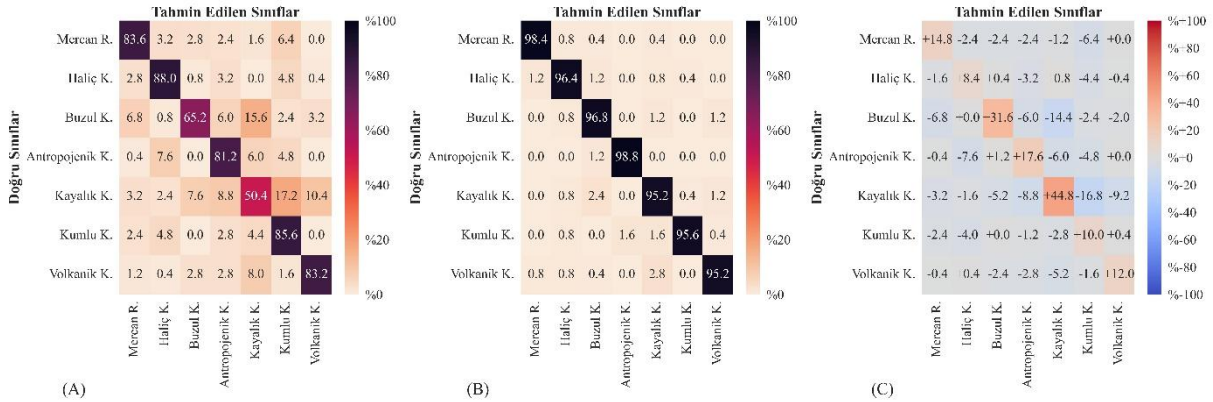

Şekil 34. R-G-B kombinasyonu için karışıklık matrisleri. (A) sıfırdan başlatılan ağırlıklar, (B) önceden eğitilen ilk ağırlıklar, (C) değişimler.

4. TARTIŞMA

Bu bölümde, Sentinel-2 uydu görüntülerinden elde edilen spektral ve dokusal özelliklerin VGG-16 modeli aracılığıyla kıyı tiplerinin sınıflandırılmasına yönelik bulgular detaylı bir şekilde tartışılmakta ve değerlendirilmektedir. Çalışma, kıyı sınıflarının yansıma özellikleri ile mekansal düzenlerinin sınıflandırma performansına etkisini incelemeyi, transfer öğreniminin katkısını değerlendirmeyi ve multispektral verilerin kıyı yönetimi uygulamalarındaki potansiyelini ortaya koymayı amaçlamaktadır. Bulgular, spektral ve dokusal özelliklerin kıyı tiplerini ayırt etmedeki önemli rolünü, modelin başarısını ve transfer öğreniminin sağladığı iyileşmeyi açıkça göstermektedir. Aşağıda, bu bulgular başlıklar halinde detaylandırılmıştır.

4.1. Spektral Özelliklerin Rolü ve NIR Bandının Önemi

Spektral analizler, kıyı sınıflarının yansıma özelliklerinde belirgin farklılıklar sergilediğini ortaya koymuştur. Yakın Kızılötesi (NIR) bandı, bitki örtüsü ve su özelliklerinin ayrıştırılmasında temel bir rol oynamıştır. Haliç Tipi Kıyılar, NIR bandında yüksek bir ortalama yansıma değeri (2702, standart sapma: 702) ile tutarlı ve ayırt edici bir spektral yanıt sergilemiş; bu, yoğun bitki örtüsünün yansıma özellikleriyle uyumludur. Mercan Resifleri, Mavi (2118), Yeşil (2462) ve Kırmızı (2141) bantlarda yüksek yansıma değerleriyle sığ suların ve parlak yüzeylerin spektral özelliklerini ortaya koymuştur. Buna karşın, Buzul Kıyıları, tüm bantlarda geniş bir yansıma aralığı ve yüksek standart sapma (örneğin, Kırmızı bantta 1840) ile geniş bir spektral yapı sergilemiş; bu, buz, kar ve gölgeler gibi farklı yüzey unsurlarının varlığına işaret etmektedir. Volkanik Kıyılar, düşük yansıma değerleri (NIR: 1835, Mavi: 1051) ile koyu renkli bazaltik yapının spektral özellikleriyle karakterize olmuştur. Bu bulgular, NIR bandının Haliç Tipi Kıyılar ve Mercan Resifleri gibi bitki örtüsü ve su yoğun sınıfların ayrıştırılmasında kritik bir katkı sağladığını ve multispektral verilerin kıyı tiplerini karakterize etmede güçlü bir araç sunduğunu doğrulamaktadır.

4.2. Dokusal Özelliklerin Rolü

Dokusal analizler, kıyı sınıflarının mekansal düzen açısından belirgin farklılıklar sergilediğini göstermiştir. Antropojenik Kıyılar (kontrast: 308,13 ve benzeşmezlik: 9,60) ve Haliç Tipi Kıyılar (kontrast: 292,16 ve benzeşmezlik: 9,86), yüksek kontrast ve benzeşmezlik değerleriyle dokusal çeşitlilik sergileyerek, kıyı yapıları, bitki örtüsü ve sediment çeşitliliğinin mekansal karmaşıklığını yansıtmaktadır. Buna karşın, Buzul Kıyılar (homojenlik: 0,41 ve enerji: 0,21) ve Volkanik Kıyılar (homojenlik: 0,37 ve enerji: 0,15), yüksek homojenlik ve enerji değerleriyle tekdüze yüzeyler göstermiştir. Kayalık Kıyılar, korelasyon ölçütünde en yüksek değeri (0,98) alarak düzenli bir dokusal yapı sergilemiştir. Bu sonuçlar, dokusal özelliklerin heterojen sınıfların (Antropojenik ve Haliç Tipi Kıyılar) ayrıştırılmasında önemli bir rol oynayarak, spektral verilerle birleştirildiğinde sınıflandırma doğruluğunu arttırabileceğini göstermektedir.

4.3. Sınıflandırma Performansı

VGG-16 modelinin performansı, R-G-B, NIR-G-B, NIR-R-G ve NIR-R-B bant kombinasyonları için sıfırdan başlatılan ağırlıklar ve transfer öğrenimi ile değerlendirilmiştir. Standart ağırlıklarla, NIR-R-B kombinasyonu %83,89 doğruluk oranıyla diğer kombinasyonlardan (R-G-B: %74,69, NIR-G-B: %74,69, NIR-R-G: %77,20) daha başarılı olmuş, NIR ve Kırmızı bantların kıyı tiplerini ayırt etmede etkili olduğunu göstermiştir. Transfer öğrenimi, tüm kombinasyonlarda doğruluğu belirgin şekilde artırmıştır: NIR-G-B'de %74,69'dan %96,97'ye, R-G-B'de %74,69'dan %96,63'e, NIR-R-G'de %77,20'den %95,89'a ve NIR-R-B'de %83,89'dan %95,94'e. Karışıklık matrisleri, transfer öğrenimi ile sınıf bazlı doğrulukların da iyileştiğini ortaya koymaktadır: Mercan Resifleri (%98,4), Haliç Tipi Kıyılar (%96,7), Buzul Kıyılar (%97,6), Antropojenik Kıyılar (%98,8), Kumlu Kıyılar (%96,7) ve Volkanik Kıyılar (%94,5) yüksek doğruluk oranları sergilerken, Kayalık Kıyılar (%91,8) nispeten daha düşük ancak etkili bir performans göstermiştir. Bu sonuçlar, transfer öğreniminin modelin spektral ve dokusal özellikleri öğrenme kapasitesini güçlendirdiğini ve zorlu sınıflarda (Kayalık Kıyılar) belirgin iyileşmeler sağladığını doğrulamaktadır.

4.4. Spektral ve Dokusal Özelliklerin Sınıflandırmaya Etkisi

Karışıklık matrisleri ve ROC eğrileri, spektral ve dokusal özelliklerin sınıflandırma performansına etkisini ayrıntılı bir şekilde göstermiştir. Standart ağırlıklarla, Antropojenik Kıyılar (%84,4) ve Haliç Tipi Kıyılar (%92,1), dokusal çeşitlilikleri sayesinde yüksek

doğrulukla ayrılmıştır. Ancak, Kayalık Kıyılar (%51,9), spektral ve dokusal benzerlikler nedeniyle Kumlu Kıyılar, Buzul Kıyıları (%10,9 karışıklık) ve Volkanik Kıyılar (%14 karışıklık) ile karışmıştır. Transfer öğrenimi, bu karışıklıkları %5'in altına indirerek Kayalık Kıyılar'ın doğruluğunu %91,8'e yükseltmiştir. ROC eğrileri, Antropojenik Kıyılar'ın spektral olarak kolayca ayırt edilebildiğini (AUC: 1,000), Mercan Resifleri'nin yüksek ayırt edicilik sunduğunu (AUC: 0,97), Buzul Kıyılar'ın etkili performans sergilediğini (AUC: 0,95), Kumlu Kıyılar'ın yüksek bir AUC değeri sergilediğini (0,98), Volkanik Kıyılar'ın etkili bir şekilde ayrıldığını (AUC: 0,94) ve Kayalık Kıyılar'ın NIR-G-B kombinasyonunda zorlandığını (AUC: 0,885) göstermiştir. Transfer öğrenimi, Kayalık Kıyılar için AUC'yi 0,995'e, Buzul Kıyılar için 0,98'e, Mercan Resifleri için 0,99'a çıkartmış ve diğer sınıflarda benzer iyileşmeler sağlamıştır. Bu bulgular, dokusal özelliklerin heterojen sınıfların ayrıştırılmasında, NIR bandının ise bitki örtüsü ve su özelliklerinin tespitinde belirleyici olduğunu doğrulamaktadır.

4.5. Transfer Öğreniminin Katkısı

Transfer öğrenimi, ImageNet üzerinde önceden eğitilmiş ağırlıklarla modelin öğrenme kapasitesini artırarak sınıflandırma performansını önemli ölçüde iyileştirmiştir. Özellikle Kayalık Kıyılar gibi spektral ve dokusal olarak diğer sınıflarla örtüşen zorlu sınıflarda, doğruluk oranı %51,9'dan %91,8'e, AUC değeri ise 0,885'ten 0,995'e yükselmiştir. Buzul Kıyılar (%70,3'ten %97,6'ya) ve Volkanik Kıyılar (%77,4'ten %94,5'e) da transfer öğreniminden faydalanmıştır. Bu iyileşmeler, transfer öğreniminin karmaşık özellikleri yakalamada etkili olduğunu ve modelin genelleme yeteneğini güçlendirdiğini göstermektedir. Ayrıca, transfer öğrenimi eğitim süresini kısaltmış ve aşırı öğrenme riskini azaltarak modelin adaptasyonunu kolaylaştırmıştır.

4.6. Bulguların Literatürle Karşılaştırması

Bu çalışmanın bulguları, derin öğrenme ve uzaktan algılama yöntemleriyle kıyı sınıflandırmasını inceleyen literatürle tutarlılık göstermektedir. NIR bandının bitki örtüsü ve su ayrımındaki rolü, Haliç Tipi Kıyılar'ın yüksek yansıma değeri (2702, standart sapma: 702) ile desteklenmekte ve Bishop-Taylor ve diğerleri (2021) multispektral görüntülerde NIR bandının önemini vurgulayan bulgularıyla paralellik göstermektedir. Pardo-Pascual ve diğerleri (2012), NIR bandının kıyı çizgisi tespitinde yüksek ayırt edicilik sağladığını bildirmiştir. Bu çalışma, NIR bandının hem Haliç Tipi Kıyılar'da hem de Mercan Resifleri'nde önemli bir rol üstlendiğini net bir şekilde göstererek literatüre özgün bir katkı sağlamıştır.

Jamali ve Mahdianpari (2022), Sentinel-1, Sentinel-2 ve LiDAR verileriyle kıyı sulak alanlarında dokusal özelliklerin doğruluğu artırdığını bildirmiştir. Bu tez, multispektral verilerle GLCM tabanlı dokusal özelliklerin avantajlarını inceleyerek hiperspektral veri bağımlılığını azaltan erişilebilir bir yaklaşım sunmaktadır. Örneğin, Jamali ve Mahdianpari (2022) hiperspektral verilerle %92,30 doğruluk elde ederken, bu çalışma multispektral verilerle %96,97 doğruluk sağlamış, bu da multispektral verilerin iddialı bir alternatif olabileceğini göstermektedir.

Transfer öğreniminin katkıları, Gonzalez-Perez ve diğerleri (2022) İHA verileriyle %85 doğruluk ve Dang ve diğerleri (2020) Vietnam kıyılarında ulaştığı yaklaşık %90 doğruluk gibi sonuçlarla karşılaştırıldığında rekabetçi düzeydedir. Multispektral verilere odaklanma, hiperspektral verilere kıyasla daha düşük maliyet ve yaygın erişilebilirlik sunar; ancak, hiperspektral verilerle karşılaştırmalı analizler, bu avantajları daha net ortaya koyabilir.

4.7. Sınırlamalar ve Gelecek Çalışmalar

Çalışmada bazı sınırlamalar belirlenmiştir. Kayalık Kıyılar (%51,9 standart doğruluk), Buzul Kıyılar (%70,3) ve Volkanik Kıyılar (%77,4) gibi spektral ve dokusal olarak benzer sınıfların ayrıştırılmasında yaşanan zorluklar, ek veri kaynaklarının (LiDAR, hiperspektral görüntüler) veya gelişmiş özellik çıkarma tekniklerinin gerekliliğini göstermektedir. Karışıklık matrisleri, bu sınıflar arasında %10-14 karışıklık olduğunu ortaya koymuş; bu, yüzey özelliklerinin (örneğin, koyu renkli bazaltik yapılar veya buz/gölge kombinasyonları) benzerliğinden kaynaklanabilir. Çevresel faktörler, örneğin bulut örtüsü veya gölgeler, yansıma değerlerini değiştirerek model performansını etkilemiş olabilir. Gelecekte, U-Net veya ResNet gibi farklı derin öğrenme mimarileri test edilebilir, dokusal özelliklere özel katmanlar eklenerek heterojen sınıfların ayrıştırılması iyileştirilebilir ve daha geniş, küresel ölçekte temsil kabiliyeti yüksek veri kümeleriyle genelleştirme artırılabilir. Hiperspektral verilerle karşılaştırmalı analizler, multispektral verilerin avantajlarını ve sınırlamalarını daha net ortaya koyabilir.

4.8. Sonuçlar

Bu çalışma, derin öğrenme yöntemleriyle kıyı alanlarının spektral ve dokusal değişkenlere dayalı sınıflandırılmasını inceleyerek, kıyı ekosistemlerinin izlenmesi ve sürdürülebilir yönetimi için yenilikçi bir çerçeve sunmuştur. Google Earth Engine (GEE) platformu ve VGG16 modeli kullanılarak, Sentinel-2 uydu görüntülerinden elde edilen verilerle yedi kıyı sınıfı—kumlu, kayalık, haliç tipi, antropojenik, mercan resifleri, volkanik ve buzul—

başarıyla sınıflandırılmıştır. GEE'nin bulut tabanlı altyapısı, 8.750 görüntülük veri setinin işlenmesini kolaylaştırmış, bulut örtüsünün filtrelenmesi gibi süreçleri hızlandırarak küresel ölçekte uygulanabilir bir çözüm sağlamıştır. Model, özellikle NIR-G-B bant kombinasyonuyla %96,97 doğruluk oranına ulaşarak yüksek performans sergilemiş, R-G-B kombinasyonu ise %96,63 ile yakın bir başarı göstermiştir (Şekil 22). Spektral analizler, yakın kızılötesi (NIR) bandının, haliç tipi kıyılar (yansıma: 2702) ve mercan resifleri (yansıma: 2118-2462) gibi bitki örtüsü ve su yoğun sınıfları ayırmada kritik bir rol oynadığını ortaya koymuştur (Tablo 5). Dokusal analizler ise antropojenik (kontrast: 308,13) ve haliç tipi kıyıların (kontrast: 292,16) heterojen yapısını vurgulayarak sınıflandırma doğruluğunu artırdığını göstermiştir (Tablo 6). Ancak, kayalık, buzul ve volkanik kıyılar gibi spektral ve dokusal örtüşme gösteren sınıfların ayrıştırılmasında zorluklar yaşanmış, bu da ek veri kaynaklarının potansiyelini göstermiştir.

Transfer öğrenimi, ImageNet veri setinden önceden eğitilmiş ağırlıklarla modelin performansını önemli ölçüde güçlendirmiştir. Sıfırdan başlatılan ağırlıklarla yapılan eğitimde NIR-R-B kombinasyonu %83,89 doğruluk oranıyla en yüksek başarıyı elde ederken, transfer öğrenimiyle NIR-G-B kombinasyonu %96,97'ye ulaşmıştır (Şekil 22). Özellikle kayalık kıyılar gibi zorlu sınıflarda doğruluk %51,9'dan %91,8'e, AUC değeri ise 0,885'ten 0,995'e çıkmıştır (Şekil 25). Buzul kıyılar (%70,3'ten %97,6'ya) ve volkanik kıyılar (%77,4'ten %94,5'e) da benzer iyileşmeler göstermiştir (Şekil 27). Karışıklık matrisleri, transfer öğrenimiyle sınıf bazlı karışıklıkların %5'in altına indiğini doğrulamış, modelin spektral ve dokusal özellikleri öğrenme kapasitesini artırdığını göstermiştir (Şekil 30). Bu bulgular, transfer öğreniminin genelleme yeteneğini güçlendirdiğini ve eğitim süresini kısaltarak aşırı öğrenme riskini azalttığını kanıtlamaktadır.

Çalışma, multispektral verilerle dokusal özelliklerin birleştirilmesiyle erişilebilir ve genellenebilir bir sınıflandırma modeli sunarak literatüre katkı sağlamıştır. 285 küresel örnekleme lokasyonuyla oluşturulan veri seti, bölgesel sınırlılıkları aşmış ve çeşitli kıyı sınıflarını bütüncül bir yaklaşımla ele almıştır. Multispektral verilerin hiperspektral veri bağımlılığını azalttığı gösterilmiş olup, bu da düşük maliyetli çözümler için önemli bir avantaj sunmaktadır. Yine de, kayalık, buzul ve volkanik kıyılar arasındaki benzerlikler nedeniyle ayrıştırma zorlukları devam etmektedir. Gelecekte, U-Net veya ResNet gibi farklı derin öğrenme mimarilerinin test edilmesi, LiDAR veya hiperspektral verilerle karşılaştırmalı analizler yapılması ve daha geniş veri kümeleriyle genelleştirmenin güçlendirilmesi

önerilmektedir. Bu çalışma, derin öğrenme ve uzaktan algılama yöntemlerinin erozyon kontrolü, habitat koruma ve sürdürülebilir kıyı yönetimi politikalarına katkısını doğrulamış, kıyı ekosistemlerinin korunması için önemli bir adım atmıştır.

KAYNAKLAR

Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., and Devin, M. (2015). *TensorFlow: Large-scale machine learning on heterogeneous systems*. Mountain View, CA: Tensorflow.

Alves, L. E. R., Gonçalves, L. G. G. de, Ávila, Á. V. A. de, Galetti, G. D., Maske, B. B., Nascimento, G. C. do, and Correia Filho, W. L. F. (2024). A New Climatology of Vegetation and Land Cover Information for South America. *Sustainability*, *16*(7), 2606.

Andréfouët, S., Kramer, P., Torres-Pulliza, D., Joyce, K. E., Hochberg, E. J., Garza-Pérez, R., and Mumby, P. J. (2003). Multi-site evaluation of IKONOS data for classification of tropical coral reef environments. *Remote Sensing of Environment*, *88*(1-2), 128-143. https://doi.org/10.1016/j.rse.2003.04.005

Andriani, G. F., and Walsh, N. (2007). Rocky coast geomorphology and erosional processes: A case study along the Murgia coastline South of Bari, Apulia—SE Italy. *Geomorphology*, *87*(3), 224-238.

Bačanin Džakula, N. (2019). Convolutional neural network layers and architectures. *Sinteza 2019-International Scientific Conference on Information Technology and Data Related Research*, 445-451. https://portal.sinteza.singidunum.ac.rs/paper/700

Bao, T., Jiao, H., Gao, S., Cai, J., and Qi, Y. (2021). Back Propagation Optimization of Convolutional Neural Network Based on the left and the right hands Identification. *2021 IEEE International Conference on Computer Science, Artificial Intelligence and Electronic Engineering (CSAIEE)*, 182-186. https://ieeexplore.ieee.org/abstract/document/9543137/

Barbier, E. B., Hacker, S. D., Kennedy, C., Koch, E. W., Stier, A. C., and Silliman, B. R. (2011). The value of estuarine and coastal ecosystem services. *Ecological Monographs*, *81*(2), 169-193. https://doi.org/10.1890/10-1510.1

Benn, D. I., and Evans, D. J. A. (2010). *Glaciers and Glaciation*. Routledge.

Bio, A., Bastos, L., Granja, H. M., Pinho, J. L., Gonçalves, J. A., Henriques, R. F., Madeira, S., Magalhães, A., and Rodrigues, D. (2015). *Methods for coastal monitoring and erosion risk assessment: Two Portuguese case studies*. https://repositorium.sdum.uminho.pt/handle/1822/43284

Bird, E. C. F. (2008). *Coastal Geomorphology: An Introduction*. John Wiley and Sons.

Bishop-Taylor, R., Nanson, R., Sagar, S., and Lymburner, L. (2021). Mapping Australia's dynamic coastline at mean sea level using three decades of Landsat imagery. *Remote Sensing of Environment*, *267*, 112734.

Dafforn, K. A., Glasby, T. M., Airoldi, L., Rivero, N. K., Mayer-Pinto, M., and Johnston, E. L. (2015). Marine urbanization: An ecological framework for designing multifunctional artificial structures. *Frontiers in Ecology and the Environment*, *13*(2), 82-90. https://doi.org/10.1890/140050

Dalrymple, R. W., Zaitlin, B. A., and Boyd, R. (1992). Estuarine facies models: Conceptual basis and stratigraphic implications. *Journal of Sedimentary Research*, *62*(6), 1130-1146. https://doi.org/10.1306/D4267A69-2B26-11D7-8648000102C1865D

Dang, K. B. (2024). Application of Artificial Intelligence for Monitoring Shoreline Changes in the Central Coast of Vietnam. *VNU Journal of Science: Earth and Environmental Sciences*, *40*(1). https://js.vnu.edu.vn/EES/article/view/5012

Dang, K. B., Nguyen, M. H., Nguyen, D. A., Phan, T. T. H., Giang, T. L., Pham, H. H., Nguyen, T. N., Tran, T. T. V., and Bui, D. T. (2020). Coastal wetland classification with deep u-net convolutional networks and sentinel-2 imagery: A case study at the tien yen estuary of vietnam. *Remote Sensing*, *12*(19), 3270.

Davis, R. A., and Fitzgerald, D. M. (2004). *Beaches and Coasts*. Blackwell Publishing.

Defeo, O., McLachlan, A., Schoeman, D. S., Schlacher, T. A., Dugan, J., Jones, A., Lastra, M., and Scapini, F. (2009). Threats to sandy beach ecosystems: A review. *Estuarine, Coastal and Shelf Science*, *81*(1), 1-12.

Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. *2009 IEEE conference on computer vision and pattern recognition*, 248-255. https://ieeexplore.ieee.org/abstract/document/5206848/

Deshmukh, D. H., Ghorpade, T., and Padiya, P. (2015). Improving classification using preprocessing and machine learning algorithms on NSL-KDD dataset. *2015 International Conference on Communication, Information and Computing Technology (ICCICT)*, 1-6. https://ieeexplore.ieee.org/abstract/document/7045674/

Ding, Y., Yang, X., Jin, H., Wang, Z., Liu, Y., Liu, B., Zhang, J., Liu, X., Gao, K., and Meng, D. (2021). Monitoring coastline changes of the malay islands based on google earth engine and dense time-series remote sensing images. *Remote Sensing*, *13*(19), 3842.

Dowdeswell, J. A., Canals, M., Jakobsson, M., Todd, B. J., Dowdeswell, E. K., and Hogan, K. A. (2016). The variety and distribution of submarine glacial landforms and implications for ice-sheet reconstruction. *Geological Society, London, Memoirs*, *46*(1), 519-552. https://doi.org/10.1144/M46.170

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., and others. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment*, *120*, 25-36.

Dugan, J. E., Airoldi, L., Chapman, M. G., Walker, S. J., and Schlacher, T. (2011). Estuarine and coastal structures: Environmental effects, a focus on shore and nearshore structures. *Treatise on Estuarine and Coastal Science*, *8*, 17-41. https://doi.org/10.1016/B978-0-12-374711-2.00802-0

Esmail, M., Mahmod, W. E., and Fath, H. (2019). Assessment and prediction of shoreline change using multi-temporal satellite images and statistics: Case study of Damietta coast, Egypt. *Applied Ocean Research*, *82*, 274-282.

Fan, J., Upadhye, S., and Worster, A. (2006). Understanding receiver operating characteristic (ROC) curves. *Canadian Journal of Emergency Medicine*, *8*(1), 19-20.

Finkl, C. W. (2004). Coastal classification: Systematic approaches to consider in the development of a comprehensive scheme. *Journal of Coastal research*, *20*(1), 166-213.

Finkl, C. W., and Makowski, C. (2020). The Biophysical Cross-shore Classification System (BCCS): Defining coastal ecological sequences with catena codification to classify cross-shore successions based on interpretation of satellite imagery. *Journal of Coastal Research*, *36*(1), 1-29.

Firth, L. B., Knights, A. M., Bridger, D., Evans, A. J., Mieszkowska, N., Moore, P. J., O'Connor, N. E., and Hawkins, S. J. (2016). Ocean sprawl: Challenges and opportunities for biodiversity management in a changing world. *Oceanography and Marine Biology: An Annual Review*, *54*, 193-269.

FitzGerald, D. M., and Hughes, Z. (2019). Marsh processes and their response to climate change and sea-level rise. *Annual Review of Earth and Planetary Sciences*, *47*(1), 481-517.

Garbin, C., Zhu, X., and Marques, O. (2020). Dropout vs. batch normalization: An empirical study of their impact to deep learning. *Multimedia Tools and Applications*, *79*(19-20), 12777-12815. https://doi.org/10.1007/s11042-019-08453-9

Gascon, F., Cadau, E., Colin, O., Hoersch, B., Isola, C., Fernández, B. L., and Martimort, P. (2014). Copernicus Sentinel-2 mission: Products, algorithms and Cal/Val. *Earth observing systems XIX*, *9218*, 455-463.

Ghaderpour, E., Mazzanti, P., Mugnozza, G. S., and Bozzano, F. (2023). Coherency and phase delay analyses between land cover and climate across Italy via the least-squares wavelet software. *International Journal of Applied Earth Observation and Geoinformation*, *118*, 103241.

Gonzalez-Perez, A., Abd-Elrahman, A., Wilkinson, B., Johnson, D. J., and Carthy, R. R. (2022). Deep and Machine Learning Image Classification of Coastal Wetlands Using Unpiloted Aircraft System Multispectral Images and Lidar Datasets. *Remote Sensing*, *14*(16), 3937.

Gorelick, N. (2013). Google earth engine. *EGU General Assembly Conference Abstracts*, *15*, 11997.

Hall-Beyer, M. (2017). Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. *International Journal of Remote Sensing*, *38*(5), 1312-1338.

Hansom, J. D. (2001). Coastal sensitivity to environmental change: A view from the beach. *Catena*, *42*(2-4), 291-305. https://doi.org/10.1016/S0341-8162(00)00144-2

Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, *SMC-3*(6), 610-621. https://doi.org/10.1109/TSMC.1973.4309314

Hintze, J. L., and Nelson, R. D. (1998). Violin plots: A box plot-density trace synergism. *The American Statistician*, *52*(2), 181-184.

Hu, Y., Zhang, J., Ma, Y., Li, X., Sun, Q., and An, J. (2019). Deep learning classification of coastal wetland hyperspectral image combined spectra and texture features: A case study of Huanghe (Yellow) River Estuary wetland. *Acta Oceanologica Sinica*, *38*, 142-150.

Hughes, T. P., Barnes, M. L., Bellwood, D. R., Cinner, J. E., Cumming, G. S., Jackson, J. B. C., Kleypas, J., van de Leemput, I. A., Lough, J. M., Morrison, T. H., and Palumbi, S. R. (2017). Coral reefs in the Anthropocene. *Nature*, *546*(7656), 82-90. https://doi.org/10.1038/nature22901

Inman, D. L., and Nordstrom, C. E. (1971). On the tectonic and morphologic classification of coasts. *The Journal of geology*, *79*(1), 1-21.

Jamali, A., and Mahdianpari, M. (2022). Swin Transformer and Deep Convolutional Neural Networks for Coastal Wetland Classification Using Sentinel-1, Sentinel-2, and LiDAR Data. *Remote Sensing*, *14*(2), 359.

Kelleher, G. (1999). *Guidelines for marine protected areas*. https://policycommons.net/artifacts/1372358/guidelines-for-marine-protected-areas/1986533/

Kenchington, R. (2009). *Maintaining coastal and lagoonal ecosystems and productivity*. https://ro.uow.edu.au/lhapapers/1682/

Kennish, M. J. (2001). Coastal salt marsh systems in the U.S.: A review of anthropogenic impacts. *Journal of Coastal Research, 17*(3), 731-748.

Komar, P. D. (1998). *Beach Processes and Sedimentation* (2. bs). Prentice Hall.

Komar, P. D. (2018). Beach processes and erosion—An introduction. İçinde *Handbook of coastal processes and erosion* (ss. 1-20). CRC Press.

Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems, 25*. https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html

LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature, 521*(7553), 436-444.

Lee, K., Sung, S. H., Kim, D., and Park, S. (2019). Verification of normalization effects through comparison of CNN models. *2019 International Conference on Multimedia Analysis and Pattern Recognition (MAPR)*, 1-5. https://ieeexplore.ieee.org/abstract/document/8743531/

Lv, Q., Wang, Q., Song, X., Ge, B., Guan, H., Lu, T., and Tao, Z. (2024). Research on coastline extraction and dynamic change from remote sensing images based on deep learning. *Frontiers in Environmental Science, 12*, 1443512.

Main-Knorn, M., Pflug, B., Louis, J., Debaecker, V., Müller-Wilm, U., and Gascon, F. (2017). Sen2Cor for sentinel-2. *Image and signal processing for remote sensing XXIII, 10427*, 37-48. https://www.spiedigitallibrary.org/conference-proceedings-of-spie/10427/0000/Sen2Cor-for-Sentinel-2/10.1117/12.2278218.short

Mbow, H.-O. P., Reisinger, A., Canadell, J., and O'Brien, P. (2017). Special Report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems (SR2). *Ginevra, IPCC, 650*. https://www.ipcc.ch/site/assets/uploads/2018/07/sr2_background_report_final.pdf

McCarthy, M. J., Colna, K. E., El-Mezayen, M. M., Laureano-Rosario, A. E., Méndez-Lázaro, P., Otis, D. B., Toro-Farmer, G., Vega-Rodriguez, M., and Muller-Karger, F. E. (2017). Satellite Remote Sensing for Coastal Management: A Review of Successful Applications. *Environmental Management, 60*(2), 323-339. https://doi.org/10.1007/s00267-017-0880-x

McLusky, D. S., and Elliott, M. (2004). *The Estuarine Ecosystem: Ecology, Threats and Management* (3. bs). Oxford University Press.

Moberg, F., and Folke, C. (1999). Ecological goods and services of coral reef ecosystems. *Ecological Economics, 29*(2), 215-233. https://doi.org/10.1016/S0921-8009(99)00009-9

Moore, J. G. (1975). Mechanism of formation of pillow lava. *American Scientist, 63*(3), 269-277.

Naranjo-Torres, J., Mora, M., Hernández-García, R., Barrientos, R. J., Fredes, C., and Valenzuela, A. (2020). A review of convolutional neural network applied to fruit image processing. *Applied Sciences, 10*(10), 3443.

Naylor, L. A., Stephenson, W. J., and Trenhaile, A. S. (2010). Rock coast geomorphology: Recent advances and future research directions. *Geomorphology, 114*(1-2), 3-11. https://doi.org/10.1016/j.geomorph.2009.02.004

Noh, H., Kwon, S., Park, Y. S., and Woo, S.-B. (2024). Application of RGB UAV imagery to sea surface suspended sediment concentration monitoring in coastal construction site. *Applied Ocean Research, 145*, 103940.

Nordstrom, K. F. (2000). *Beaches and Dunes of Developed Coasts*. Cambridge University Press.

Pardo-Pascual, J. E., Almonacid-Caballer, J., Ruiz, L. A., and Palomar-Vázquez, J. (2012). Automatic extraction of shorelines from Landsat TM and ETM+ multi-temporal images with subpixel precision. *Remote Sensing of Environment*, *123*, 1-11.

Patsch, K., King, P., Reineman, D. R., Jenkins, S., Steele, C., Gaston, E., and Anderson, S. (2021). Beach sustainability assessment: The development and utility of an interdisciplinary approach to sandy beach monitoring. *Journal of Coastal Research*, *37*(6), 1130-1157.

Ramalho, R. S., Quartau, R., Trenhaile, A. S., Mitchell, N. C., Woodroffe, C. D., and Ávila, S. P. (2013). Coastal evolution on volcanic oceanic islands: A complex interplay between volcanism, erosion, and sedimentation. *Earth-Science Reviews*, *127*, 140-170. https://doi.org/10.1016/j.earscirev.2013.10.003

Santos, C. F. G. D., and Papa, J. P. (2022). Avoiding Overfitting: A Survey on Regularization Methods for Convolutional Neural Networks. *ACM Computing Surveys*, *54*(10s), 1-25. https://doi.org/10.1145/3510413

Sharma, S., Sharma, S., and Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, *6*(12), 310-316.

Shepard, F. P. (1940). Submarine geology and geophysics. *Nature*, *146*(3700), 431-432.

Simonyan, K., and Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*.

Spalding, M., Ravilious, C., and Green, E. P. (2001). *World atlas of coral reefs*. Univ of California Press.

Spoto, F., Sy, O., Laberinti, P., Martimort, P., Fernandez, V., Colin, O., Hoersch, B., and Meygret, A. (2012). Overview of sentinel-2. *2012 IEEE International Geoscience and Remote Sensing Symposium*, 1707-1710.

Susmaga, R. (2004). Confusion Matrix Visualization. İçinde M. A. Kłopotek, S. T. Wierzchoń, and K. Trojanowski (Ed.), *Intelligent Information Processing and Web Mining* (ss. 107-116). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-39985-8_12

Syvitski, J. P., Burrell, D. C., and Skei, J. M. (2012). *Fjords: Processes and products*. Springer Science and Business Media.

Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, *9*(10), 143-150.

Tarrio, K., Tang, X., Masek, J. G., Claverie, M., Ju, J., Qiu, S., Zhu, Z., and Woodcock, C. E. (2020). Comparison of cloud detection algorithms for Sentinel-2 imagery. *Science of Remote Sensing*, *2*, 100010.

Teodoro, A. C. (2016). Optical satellite remote sensing of the coastal zone environment—An overview. Environment Applications of Remote Sensing. *London, UK, InTechOpen*, 165-196.

Thompson, R., Crowe, T., and Hawkins, S. (2002). Rocky intertidal communities: Past environmental changes, present status and predictions for the next 25 years. *Environmental conservation*, *29*(2), 168-191.

Thornton, I. (2007). *Island Colonization: The Origin and Development of Island Communities*. Cambridge University Press.

Vani, S., and Rao, T. M. (2019). An experimental approach towards the performance assessment of various optimizers on convolutional neural network. *2019 3rd international conference on trends in electronics and informatics (ICOEI)*, 331-336. https://ieeexplore.ieee.org/abstract/document/8862686/

Vedaldi, A., and Zisserman, A. (2016). Vgg convolutional neural networks practical. *Department of Engineering Science, University of Oxford*, *66*.

Ventura, D., Bonifazi, A., Gravina, M. F., Belluscio, A., and Ardizzone, G. (2018). Mapping and classification of ecologically sensitive marine habitats using unmanned aerial vehicle (UAV) imagery and object-based image analysis (OBIA). *Remote Sensing*, *10*(9), 1331.

Vitousek, S., Buscombe, D., Vos, K., Barnard, P. L., Ritchie, A. C., and Warrick, J. A. (2023). *The future of coastal monitoring through satellite remote sensing*. Coastal Futures, 1, e10. https://www.cambridge.org/core/journals/cambridge-prisms-coastal-futures/article/future-of-coastal-monitoring-through-satellite-remote-sensing/CEDC8CD6260C8FA6E10DD148AE50BF4E

Vos, K., Splinter, K. D., Harley, M. D., Simmons, J. A., and Turner, I. L. (2019). CoastSat: A Google Earth Engine-enabled Python toolkit to extract shorelines from publicly available satellite imagery. *Environmental Modelling and Software*, *122*, 104528.

Wen, L., Li, X., and Gao, L. (2020). A new reinforcement learning based learning rate scheduler for convolutional neural network in fault classification. *IEEE Transactions on Industrial Electronics*, *68*(12), 12890-12900.

Williams, S. J. (2013). Sea-level rise implications for coastal regions. *Journal of Coastal Research*, *63*, 184-196.

World Bank. (2016). *World development indicators 2016*. https://policycommons.net/artifacts/1519591/world-development-indicators-2006/2199923/

Yao, P., Su, M., Wang, Z., van Rijn, L. C., Zhang, C., Chen, Y., and Stive, M. J. (2015). Experiment inspired numerical modeling of sediment concentration over sand–silt mixtures. *Coastal Engineering*, *105*, 75-89.

Yosinski, J., Clune, J., Bengio, Y., and Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in neural information processing systems*, *27*. https://proceedings.neurips.cc/paper/5347-how-transferable-are-features-in-deep-n%E2%80%A6

Zeiler, M. D., and Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. Içinde D. Fleet, T. Pajdla, B. Schiele, and T. Tuytelaars (Ed.), *Computer Vision – ECCV 2014* (C. 8689, ss. 818-833). Springer International Publishing. https://doi.org/10.1007/978-3-319-10590-1_53

Zelaya, C. V. G. (2019). Towards explaining the effects of data preprocessing on machine learning. *2019 IEEE 35th international conference on data engineering (ICDE)*, 2086-2090. https://ieeexplore.ieee.org/abstract/document/8731532/

Zitouni, M. S., Elneel, L., Assad Albakri, N., Alkhatib, M. Q., and Al-Ahmad, H. (t.y.). Forecasting Sea Level Rise Using Enhanced Deep Learning Models. *Frontiers in Environmental Science*, *13*, 1552834.

EKLER

EK 1. Model Eğitim ve Doğrulama Grafikleri

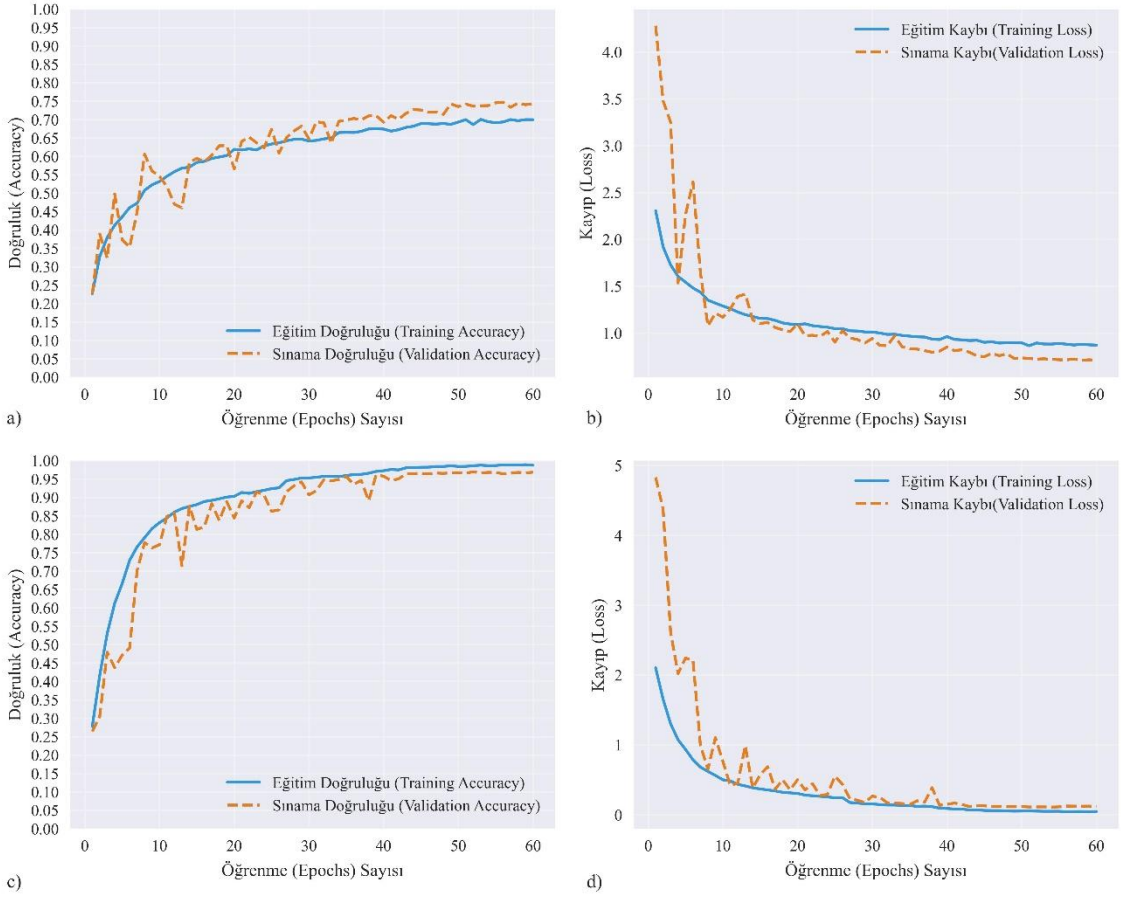

Şekil 35. İsabetlilik ve kayıp değerleri (R-G-B veri seti). (A) ve (B) sıfırdan başlatılan ağırlıklar, (C) ve (D) önceden eğitilen ilk ağırlıklar.

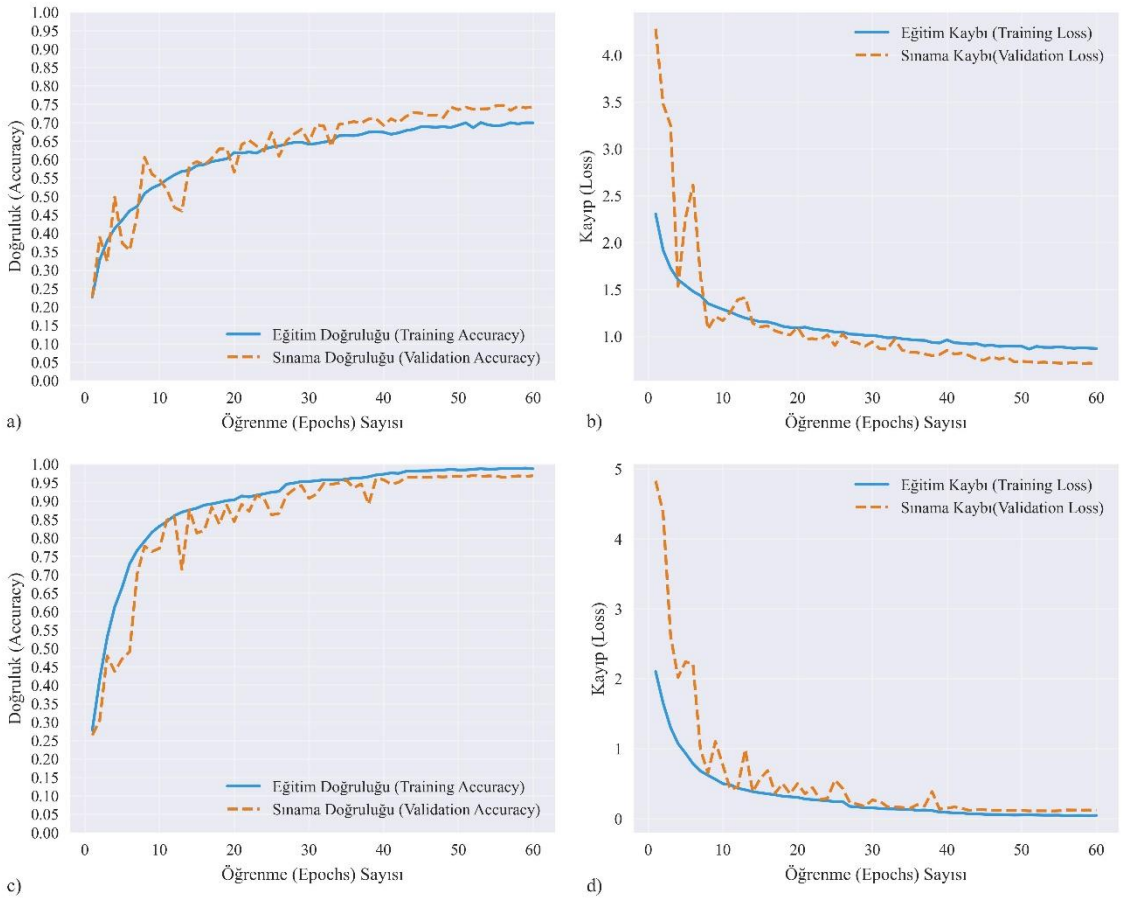

Şekil 36. İsabetlilik ve kayıp değerleri (NIR-G-B veri seti). (A) ve (B) sıfırdan başlatılan ağırlıklar, (C) ve (D) önceden eğitilen ilk ağırlıklar.

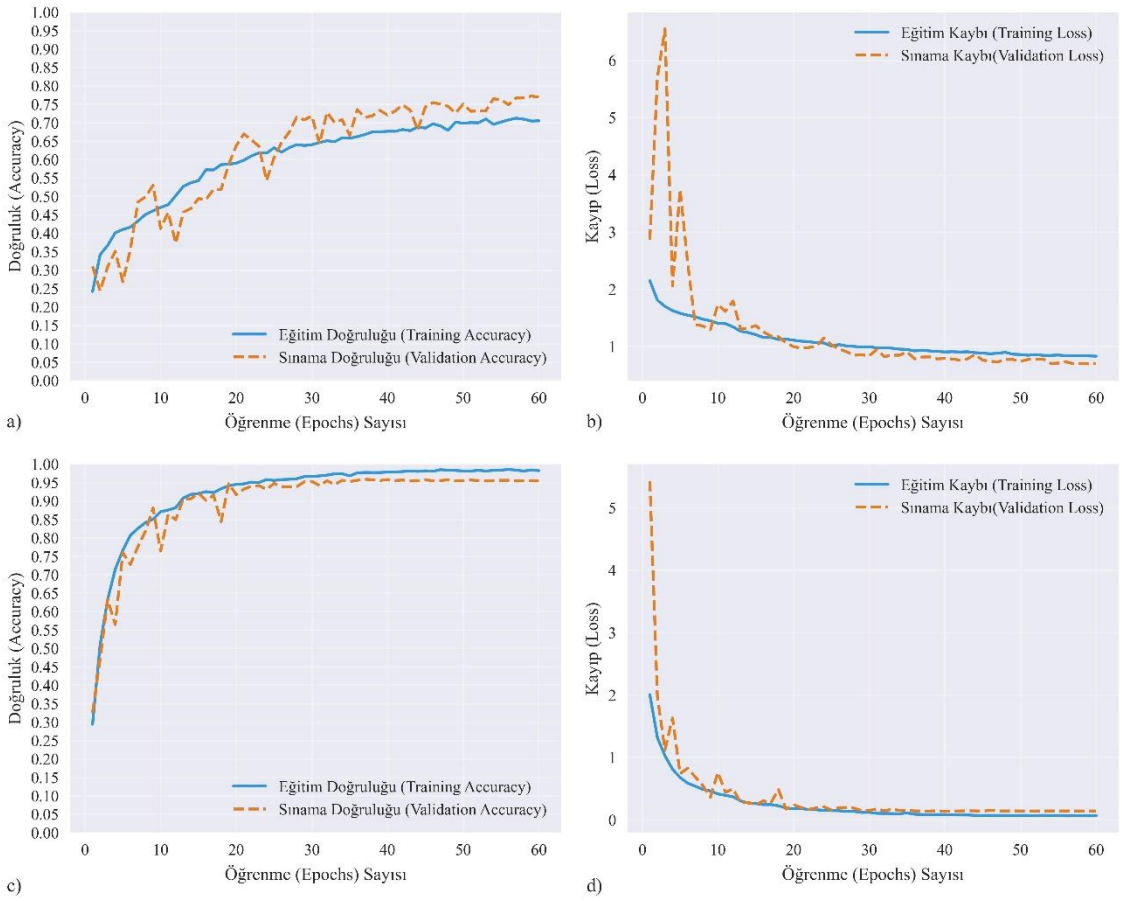

Şekil 37. İsabetlilik ve kayıp değerleri (NIR-R-G veri seti). (A) ve (B) sıfırdan başlatılan ağırlıklar, (C) ve (D) önceden eğitilen ilk ağırlıklar.

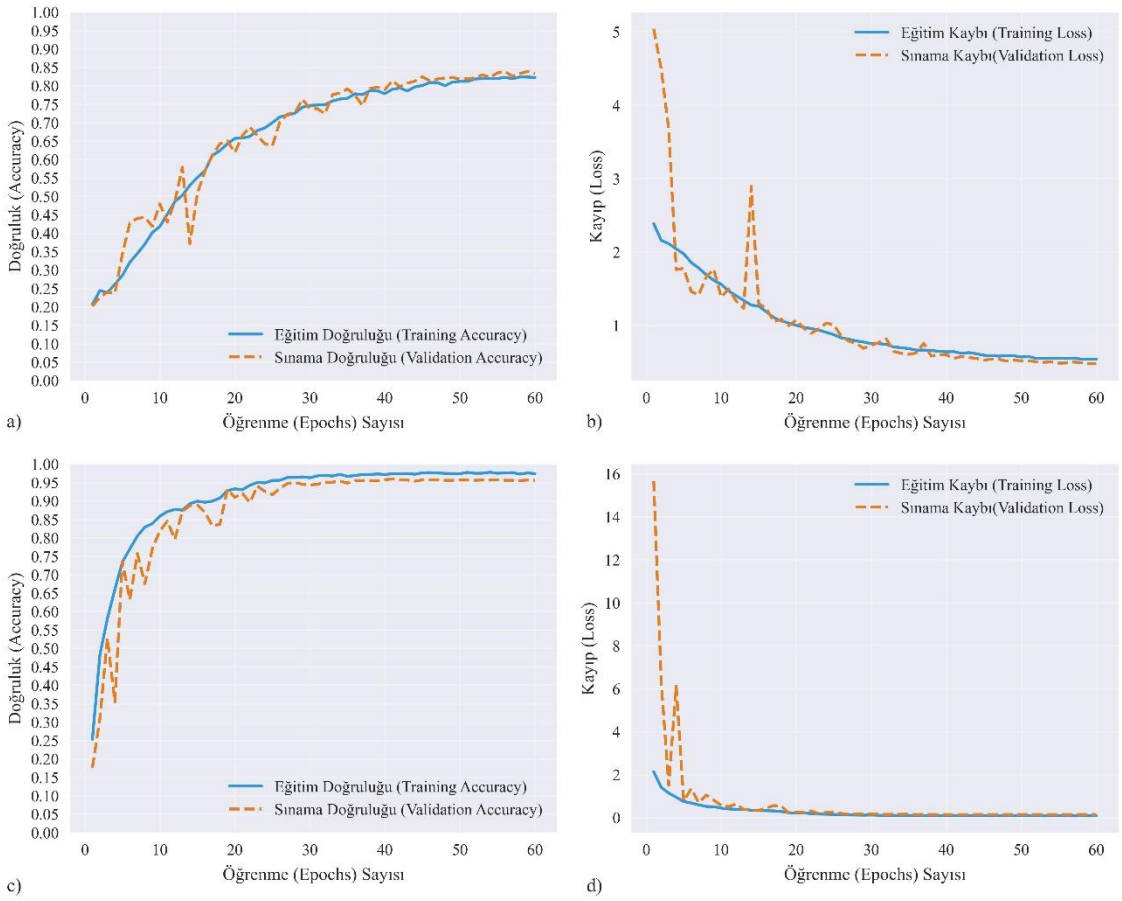

Şekil 38. İsabetlilik ve kayıp değerleri (NIR-R-B veri seti). (A) ve (B) sıfırdan başlatılan ağırlıklar, (C) ve (D) önceden eğitilen ilk ağırlıklar.

ÖZGEÇMİŞ

Lise : (2005-2009), Hüseyin Bürge Anadolu Lisesi
Lisans : (2010-2016), Yıldız Teknik Üniversitesi/İnşaat Mühendisliği
Yüksek Lisans : (2020-2025), İ.Ü. Deniz Bilimleri ve İşletmeciği Enstitüsü
Çalıştığı Kurum : (2017-2019), Denar Deniz Araştırmaları A.Ş.
ORCID Kimliği : 0000-0002-3788-9988
Bilimsel Etkinlikleri : Makale:

Çelik, O. İ., Büyüksalih, G., and Gazioğlu, C. (2023). Improving the Accuracy of Satellite-Derived Bathymetry Using Multi-Layer Perceptron and Random Forest Regression Methods: A Case Study of Tavşan Island. Journal of Marine Science and Engineering, 11(11), 2090.

Çelik, O. İ., and Gazioğlu, C. (2020). Coastline difference measurement (CDM) method. International Journal of Environment and Geoinformatics, 7(1), 1-5.

Çelik, O. İ., and Gazioğlu, C. (2022). Coast type based accuracy assessment for coastline extraction from satellite image with machine learning classifiers. The Egyptian Journal of Remote Sensing and Space Science, 25(1), 289-299. https://doi.org/10.1016/j.ejrs.2022.01.010

Çelik, O. İ., and Gazioğlu, C. (2024). Leveraging deep learning for coastal monitoring: A VGG16-based approach to spectral and textural classification of coastal areas with sentinel-2A data. Applied Ocean Research, 151, 104163.

Bildiri:

Gazioğlu, C., Çelik, O., and Çelik, S. (2022). Marmara Denizi için 2002-2021 Yılları Arasında Klorofil-A Değerlerinin Google Earth Engine Yardımı ile İzlenmesi. TÜDAV Marmara Sempozyumu 2022. https://scholar.google.com/scholar?cluster=15473026651045786741andhl=enandoi=scholarr

Büyüksalih, G., Gazioğlu, C., Çelik, O. İ., and Jacobsen, K. (2023). Geometry and Image Quality Assessment of SkySat Imagery for Building Identification. 2023 10th International Conference on Recent Advances in Air and Space Technologies (RAST), 1-4. https://ieeexplore.ieee.org/abstract/document/10197952/

T.C.
İSTANBUL ÜNİVERSİTESİ
DENİZ BİLİMLERİ VE İŞLETMECİLİĞİ ENSTİTÜSÜ

TEZ BENZERLİK RAPORU UYGUNLUK FORMU

ÖĞRENCİNİN ADI SOYADI	: Osman İsa ÇELİK
ÖĞRENCİ NO	: 3002200002
ÖĞRETİM YILI	: 2024-2025
ANABİLİM DALI / BİLİM DALI	: Denizel Çevre Ana Bilim Dalı, Kıyı Mühendisliği
PROGRAM TÜRÜ	**: YÜKSEK LİSANS ▫ DOKTORA ■**
TEZ DANIŞMANI ÜNVANI ADI SOYADI	**:**Prof Dr. Cem GAZİOĞLU
II. TEZ DANIŞMANI ÜNVAN ADI SOYADI	**: -**
TEZ BAŞLIĞI	**:**DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ

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 66 sayfalık kısmına ilişkin, 08/05/2025 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 'tür.

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 sorumluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu beyan ederim.

Gereğini arz ederim.

İmza
Osman İsa ÇELİK
Tarih: 08/05/2025

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

DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ

Yazar Osman İsa ÇELİK

Gönderim Tarihi: 08-May-2025 07:55PM (UTC+0300)
Gönderim Numarası: 2670357084
Dosya adı: Doktora_Tezi_Osman_Isa_Celik_Benzerlik_Kontrolu.docx (141.09K)
Kelime sayısı: 12890
Karakter sayısı: 90984

DERİN ÖĞRENME İLE KIYI ALANLARININ SPEKTRAL VE DOKUSAL DEĞİŞKENLERE GÖRE BELİRLENMESİ

ORİJİNALLİK RAPORU

%3	%2	%1	%1
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	www.ipi.uni-hannover.de İnternet Kaynağı	<%1
2	Mercan, Öykü Berfin. "Akıllı telefon tabanlı kolorimetrik glikoz tayininde yapay zeka yaklaşımı", Izmir Katip Celebi University (Turkey), 2024 Yayın	<%1
3	dergipark.org.tr İnternet Kaynağı	<%1
4	www.ubakkongre.com İnternet Kaynağı	<%1
5	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	<%1
6	acikbilim.yok.gov.tr İnternet Kaynağı	<%1
7	www.isarconference.org İnternet Kaynağı	<%1
8	Submitted to Bülent Ecevit Üniversitesi Öğrenci Ödevi	<%1
9	abakus.inonu.edu.tr İnternet Kaynağı	<%1
10	Doğru, Hasibe Büşra. "Yapay zeka ile ortak yönelimli web sitelerinin tespiti", Istanbul Sabahattin Zaim University (Turkey) Yayın	<%1

doczz.biz.tr

11	İnternet Kaynağı	<%1
12	www.bitkiortusu.gen.tr İnternet Kaynağı	<%1
13	Submitted to Kirsehir Ahi Evran Universitesi Öğrenci Ödevi	<%1
14	arxiv.org İnternet Kaynağı	<%1
15	ojs.upv.es İnternet Kaynağı	<%1
16	acikerisim.subu.edu.tr İnternet Kaynağı	<%1
17	acikkaynak.bilecik.edu.tr İnternet Kaynağı	<%1
18	fenix.tecnico.ulisboa.pt İnternet Kaynağı	<%1
19	rodin.uca.es İnternet Kaynağı	<%1
20	www.ctf.edu.tr İnternet Kaynağı	<%1

Alıntıları çıkart	üzerinde	Eşleşmeleri çıkar	< 5 words
Bibliyografyayı Çıkart	üzerinde		

Applied Ocean Research 151 (2024) 104163



Contents lists available at ScienceDirect

Applied Ocean Research

journal homepage: www.elsevier.com/locate/apor





Leveraging deep learning for coastal monitoring: A VGG16-based approach to spectral and textural classification of coastal areas with sentinel-2A data

Osman İsa Çelik *, Cem Gazioğlu

Department of Marine Environment, Institute of Marine Sciences and Management, Istanbul University, Vefa-Fatih, Istanbul, 34134, Turkey

ARTICLE INFO

Keywords:
Sentinel-2A
Google Earth engine
Deep learning
VGG16
Transfer learning

ABSTRACT

Coastal ecosystems are vital for the planet's health, providing essential habitats for diverse species and supporting human communities. However, these complex environments face increasing threats from climate change and human activities. Effective monitoring of these areas requires large-scale, efficient, and accurate methods. This study explores the potential of deep learning for automated coastal land cover classification using Sentinel-2A satellite imagery on the Google Earth Engine (GEE) platform. We investigate the impact of transfer learning and spectral band combinations on classification accuracy for five coastal types: artificial, bedrock, sandy, muddy, and vegetation-covered. Our findings demonstrate that a pre-trained VGG16 Convolutional Neural Network (CNN) with transfer learning significantly improves classification accuracy (average 19.3% increase) compared to using default weights. Notably, including the near-infrared (NIR) band in training data leads to superior results, particularly for artificial and bedrock coastlines, where the NIR band's effectiveness in separating land-water boundaries enhances classification accuracy. These results highlight the potential of deep learning for large-scale, automated coastal monitoring, informing applications in sustainable fisheries management, coastal vulnerability assessment, and marine ecosystem conservation.

1. Introduction

Marine ecosystems thrive with vibrant biodiversity, with flourishing coral reefs, expansive seagrass meadows, and vital mangrove forests blanketing our coastlines (Kenchington, 2009). These regions serve not only as cradles of life but also as critical economic engines, sustaining over half of the world's population residing in coastal zones, according to the World Bank (World Bank, 2016). From productive fisheries to fertile agricultural lands, coastal ecosystems provide a plethora of resources, underpinning tourism, recreation, and shipping industries (Kelleher, 1999). However, these dynamic zones face a confluence of intensifying human activities and climate change.

Recent studies have explored the relationship between climate and land cover across coastal regions. For example, a study on Italy employed coherency and phase delay analyses (Ghaderpour et al., 2023) to investigate the connection between vegetation and climate. Their findings revealed that the annual cycles of normalized difference vegetation index (NDVI) and land surface temperature (LST) were approximately in-phase in most ecoregions, indicating a strong coupling between these factors. Another study in South America presented a new, highly accurate dataset on vegetation and land cover (Alves et al., 2024). These findings highlight the importance of understanding the complex interactions between land cover and climate in coastal environments.

Rising sea levels, fueled by a warming planet, inundate low-lying coastal areas, eroding shorelines and displacing communities (Williams, 2013). Agricultural runoff laden with fertilizers and pesticides pollutes coastal waters, while destructive fishing practices like bottom trawling significantly degrade delicate habitats (Mbow et al., 2017). Consequently, a more comprehensive understanding of coastal dynamics is paramount to ensure the effective management and preservation of these vital ecosystems (McCarthy et al., 2017).

Traditional methods of coastal monitoring often prove to be time-consuming and subjective, limiting their efficacy in large-scale applications (Bio et al., 2015; Ventura et al., 2018). Fortunately, advancements in technology offer powerful tools for studying and managing these complex environments (Noh et al., 2024). Remote sensing technologies, particularly satellite imagery, provide scientists with a unique synoptic perspective (Vitousek et al., 2023). By capturing vast swathes of the Earth's surface from space, satellites offer high-resolution data,

* Corresponding author.
E-mail address: - (O.İ. Çelik).

https://doi.org/10.1016/j.apor.2024.104163
Received 18 April 2024; Received in revised form 15 July 2024; Accepted 5 August 2024
Available online 14 August 2024
0141-1187/© 2024 Elsevier Ltd. All rights are reserved, including those for text and data mining, AI training, and similar technologies.