

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**UZAKTAN ALGILAMA VERİLERİ KULLANARAK DERİN ÖĞRENMEYE
DAYALI ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ HARİTALAMA MODELİ
GELİŞTİRME**

DOKTORA TEZİ

Şaziye Özge ATİK

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

ARALIK 2021

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**UZAKTAN ALGILAMA VERİLERİ KULLANARAK DERİN ÖĞRENMEYE
DAYALI ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ HARİTALAMA MODELİ
GELİŞTİRME**

DOKTORA TEZİ

**Şaziye Özge ATİK
(501152607)**

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Cengizhan İPBÜKER

ARALIK 2021

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501152607 numaralı Doktora Öğrencisi Şaziye Özge ATİK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “UZAKTAN ALGILAMA VERİLERİ KULLANARAK DERİN ÖĞRENMEYE DAYALI ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ HARİTALAMA MODELİ GELİŞTİRME” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Cengizhan İPBÜKER**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Dursun Zafer ŞEKER**
İstanbul Teknik Üniversitesi

Doç. Dr. İsmail ÇÖLKESEN
Gebze Teknik Üniversitesi

Prof. Dr. Ergin TARI
İstanbul Teknik Üniversitesi

Prof. Dr. Semih EKERCİN
Necmettin Erbakan Üniversitesi

Teslim Tarihi : 09 Kasım 2021
Savunma Tarihi : 02 Aralık 2021





Eşim Enes, oğlum Ömer Eymen ve anneme;



ÖNSÖZ

Çoğunlukla keyifle ilerleyen doktora tezi yolculuğumda zaman zaman yorulup zorlandığımda; nice uzun soluklu işlerin tamamlanması için çaba ve sabrın gerekliliğini hatırladım. Allah'a şükür, süreci tamamlıyor olmanın verdiği mutluluk ise, bu yolculuğun her adımına değiyor. Şimdiye dek en uzun soluklu olan bu uğraşım için, başta eşim Muhammed Enes ATİK'e maddi ve manevi verdiği destek için teşekkür ederim. Tezin her aşamasında sağladığı katkı ve kesintisiz motivasyon için minnettirim. Tüm öğrenim hayatım boyunca varlığıyla, öğretisiyle, desteğiyle hep daha rahat ilerlediğim, üzerimde en çok emeği olan insan, annem Sevgi DÖNMEZ'e teşekkür ederim. Babam Niyazi DÖNMEZ ve kardeşlerime, çalışma yoğunluğuyla yeri gelip tatilde bile bir araya gelemediğimiz tüm bu yıllar içindeki destekleri, anlayışları ve üzerimdeki emekleri için teşekkür ederim.

Lisans öğrenimimden itibaren, mesleki kazanımlarımda üzerimde emeği çok büyük, akademik yolculukta her zaman örnek aldığım rehberim olan, tez danışmanım Prof. Dr. Cengizhan İPBÜKER'e tezin ilk gününden sonuna kadar her dönem kesintisiz sağladığı şevk ve kıymetli katkıları için teşekkür ederim. Tez çalışması boyunca, bilgi birikimi ve tecrübesiyle yol gösteren Prof. Dr. Dursun Zafer ŞEKER'e teşekkür ederim. Tezi geliştirmeye dair verdiği tavsiyelerle teze birçok katkı sağlayan Doç. Dr. İsmail ÇÖLKESEN'e teşekkür ederim. Bu süreçte, akademik ziyaretçi olarak gittiğim Twente Üniversitesi ITC EOS departmanında tez araştırmalarımda bulunmama olanak tanıyan Prof. Dr. George VOSSelman ve Prof. Dr. Alfred STEIN'a teşekkür ederim. Oradaki çalışmalarımı beni özenle ve sabırla dinleyen süpervizörüm Dr. Öğr. Üyesi Mariana BELGIU'ya katkıları için teşekkür ederim.

Prof. Dr. Mustafa YANALAK'a tez çalışmalarımı UHUZAM bünyesinde yazılım kullanmama olanak tanıdığı ve İTÜ'de çalıştığım süre boyunca akademik desteği için teşekkür ederim. GTÜ yüksek hesaplamalı bilgisayar laboratuvarının kullanımına olanak verdiği ve her daim akademik çalışmalara desteği için Prof. Dr. Taşkın KAVZOĞLU'na teşekkür ederim. Görüş ve katkılarından dolayı Prof. Dr. Ergin TARI, Prof. Dr. Semih EKERCİN ve Prof. Dr. Coşkun ÖZKAN'a teşekkür ederim.

İTÜ Geomatik Mühendisliği bölümünde lisansüstü eğitimim ve yıllar süren araştırma görevliliğim süresince verdikleri katkı, sağladıkları destek için, üzerimde emeği olan tüm hocalarıma ve çalışma arkadaşlarıma ayrı ayrı teşekkür ederim. GTÜ Harita Mühendisliği bölümündeki tüm hocalara ve çalışma arkadaşlarıma, sağladıkları bu akademik atmosfer ve destekleri için teşekkürü borç bilirim.

Bu çalışma, İstanbul Teknik Üniversitesi Bilimsel Araştırma Projeleri (BAP) Birimi tarafından MDK-2018-41541 sayılı proje ile desteklenmiştir.

Kasım 2021

Şaziye Özge ATİK
(Geomatik Y. Müh.)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1 Tezin Amacı	4
1.2 Yöntem	6
1.3 Uzaktan Algılama Alanında Derin Öğrenme Uygulamaları	7
1.4 Arazi Kullanımı ve Arazi Örtüsü Sınıflandırmasında Uzaktan Algılama Teknolojilerinin Kullanımı.....	10
1.5 Literatür Araştırması	13
2. MATERYAL VE YÖNTEM.....	23
2.1 Uygulamada Kullanılan Veri Setleri	23
2.1.1 Sentinel-2 veri seti	23
2.1.2 Zurich Summer Veri Seti.....	27
2.1.3 Wuhan University Building Extraction Dataset (WHUBED) Veri Seti....	28
2.2 Evrimsel Sinir Ağları (ESA).....	29
2.2.1 U-Net mimarisi	30
2.2.2 SegNet mimarisi	31
2.2.3 DeepLabV3+ mimarisi	32
2.2.4 ResNet	34
2.2.5 Mobilenetv2.....	36
2.2.6 Xception.....	37
2.3 Spektral İndeks	39
2.3.1 Normalize edilmiş vejetasyon fark indeksi (NDVI).....	39
2.3.2 Basit oran indeksi (SR).....	39
2.3.3 Diferansiyel vejetasyon indeksi (DVI)	39
2.4 Nesne Tabanlı Görüntü Analizi.....	40
2.5 Çoklu-Çözünürlüklü Bölütleme (Multi-Resolution Segmentation).....	41
2.6 Çoğunluk Oylama (Majority Voting).....	42
2.7 Mc-Nemar Testi	43
3. UYGULAMA.....	45
3.1 Sentinel-2 Veri Setinin Deneysel Sonuçları.....	45
3.2 McNemar Testi.....	65
3.3 Zurich Summer Veri Seti Deneysel Sonuçları	66

3.4 Bölütleme Kalitesi	74
3.5 WHUBED Deneysel Sonuçları	76
4. TARTIŞMA	83
5. SONUÇ VE ÖNERİLER	87
KAYNAKLAR.....	89
ÖZGEÇMİŞ.....	99



KISALTMALAR

AD	: Ağırlıklı doğruluk
AFİ	: Area fit index
AK	: Arazi kullanımı
AKAÖ	: Arazi örtüsü arazi kullanımı
ASPP	: Atrous Spatial Pyramid Pooling
AÖ	: Arazi örtüsü
AUI	: Alan uyum indeksi
CBS	: Coğrafi Bilgi Sistemleri
CLC	: Corine Land Cover
CLCMGB	: Büyük Britanya CLC haritası
CORINE	: Coordination of Information on the Environment
CRF	: Koşullu rastgele alanları
ÇÇB	: Çoklu-çözünürlüklü bölütleme
ÇYÇ	: Çok yüksek çözünürlüklü
DAE	: Derinlemesine Ayrılabilir Evrişimler
DESA	: Derin evrişimsel sinir ağları
DBN	: Deep Belief Networks
DLR	: Alman Havacılık ve Uzay Merkezi
DÖ	: Derin öğrenme
DVI	: Differential Vegetation Index
ESA	: Evrişimsel sinir ağları
FAO	: Gıda ve Tarım Örgütü
FCN	: Fully Convolutional Networks
GD	: Genel doğruluk
GT	: Referans Verisi
IoU	: Intersection over Union
ILSVRC	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
KO	: Kalite Oranı

KOH	: Karesel ortalama hata
LCCS	: Arazi örtüsü sınıflandırma sistemi
LCI	: Arazi örtüsü enstitüsü
MSG	: Multispektral görüntüler
NDVI	: Normalized Difference Vegetation Index
NIR	: Yakın kızıl-ötesi
NLCD	: Amerika Birleşik Devletleri için Ulusal Arazi Örtüsü Veritabanı
NTGA	: Nesne tabanlı görüntü analizi
OD	: Ortalama doğruluk
OS	: Üst-bölütleme
ReLU	: Rectified Linear Unit
SAM	: Sayısal arazi modeli
SDG	: Sustainable Development Goal
SY	: Su yapıları
SYM	: Sayısal yükseklik modeli
SR	: Simple Ratio
UA	: Uzaktan algılama
US	: Alt-bölütleme
USGS	: Birleşmiş Milletler Jeoloji Araştırmaları Kurumu
VGG	: Visual geometry group
WHUBED	: Wuhan University Building Extraction Dataset
YDA	: Orman ve yarı doğal alanlar
YG	: Yer gözlemi
YY	: Yapay yüzeyler

SEMBOLLER

A_b	: Bölütleme sonucunda elde edilen nesne alanı
A_s	: Referans nesne alanı
b	: Ön-gerilim vektörü
Cat_c	: Sınıf kategorisi
Cat_m	: Belirlenen yeni kategori
f_{21}	: Yanlış sınıflandırılan
$h_{biçim}$	: Şekil parametresi
H_i	: Nesne için çoğunluk kategorisi
h_{renk}	: Renk parametresi
n	: Sınıf sayısı
r	: Atrous oranı
S_c	: NTGA sonucu elde edilen bölüt
t	: Eşik değer
w	: Ağırlık vektörü
x_k	: Aktivasyon fonksiyonun girdisi



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Sentinel 2A uydusunun özellikleri	26
Çizelge 2.2 : Sentinel veri setinde sınıf dağılımları.....	26
Çizelge 2.3 : Zurich Summer veri seti sınıf dağılımı.....	28
Çizelge 2.4 : WHUBED veri seti sınıf istatistikleri.....	29
Çizelge 2.5 : Çalışmada kullanılan multi-spektral indisler.....	40
Çizelge 2.6 : İki model arasında olasılık (contingency) matrisi genel gösterimi	43
Çizelge 3.1 : 5 bantlı İstanbul test alanı: U-Net ile değerlendirme ölçütleri.	47
Çizelge 3.2 : 5 bantlı İstanbul test alanı: SegNet ile değerlendirme ölçütleri.	47
Çizelge 3.3 : 7 bantlı İstanbul test alanı: U-Net ile değerlendirme ölçütleri.	49
Çizelge 3.4 : 7 bantlı İstanbul test alanı: SegNet ile değerlendirme ölçütleri.	49
Çizelge 3.5 : 5 bantlı Kocaeli test alanı: U-Net ile değerlendirme ölçütleri.....	55
Çizelge 3.6 : 5 bantlı Kocaeli test alanı: SegNet ile değerlendirme ölçütleri.....	55
Çizelge 3.7 : 7 bantlı Kocaeli test alanı: U-Net ile değerlendirme ölçütleri.....	59
Çizelge 3.8 : 7 bantlı Kocaeli test alanı: SegNet ile değerlendirme ölçütleri.....	59
Çizelge 3.9 : Modeller için McNemar test sonuçları	66
Çizelge 3.10 : Zurich Summer veri seti ZH-16 görüntüsünün deneysel sonuçları...	67
Çizelge 3.11 : Zurich Summer veri seti ZH-17 görüntüsü için deneysel sonuçları...	71
Çizelge 3.12 : Zurich Summer veri seti sonuçlarının literatür ile karşılaştırılması ...	74
Çizelge 3.13 : Sentinel veri seti için bölütleme kalite ölçütleri.	75
Çizelge 3.14 : Zurich Summer veri seti için bölütleme kalite ölçütleri.....	76
Çizelge 3.15 : 003 görüntüsüne ait ESA ve ESA+ÇÇB değerlendirme ölçütleri.....	81
Çizelge 3.16 : 055 görüntüsüne ait ESA ve ESA+ÇÇB değerlendirme ölçütleri.....	81



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Tez çalışmasının genel akış diyagramı.....	7
Şekil 1.2 : Uzaktan algılama verileriyle AKAÖ hakkında beş yıllık aralıklarla Scopus veri tabanındaki trendler.....	8
Şekil 1.3 : Nesne tespiti ve örnek segmentasyon uygulaması – Otomatik gemi çıkarımı.	9
Şekil 1.4 : Sol semantik segmentasyon, sağ instance (örnek) segmentasyon.....	9
Şekil 1.5 : Segmentasyon türleri.....	9
Şekil 1.6 : Uzaktan algılamada derin öğrenmede dört temel görev.....	10
Şekil 1.7 : Tekil, çoklu sınıf, çoklu etiketli sınıflandırma çeşitleri.	10
Şekil 1.8 : Birleşmiş Milletler SGD Amaçları.....	13
Şekil 2.1 : Türkiye'de çalışma alanı için seçilen illerin dağılımı.....	24
Şekil 2.2 : İstanbul şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri. .	24
Şekil 2.3 : Kocaeli şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri..	25
Şekil 2.4 : Muğla şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri....	25
Şekil 2.5 : Zurich Summer veri setinden (ZH-12) örnek görüntü.	27
Şekil 2.6 : Zurich Summer veri seti sınıflarının yoğunluk gösterimi.	28
Şekil 2.7 : WHUBED veri setine ait bazı görüntüler.	29
Şekil 2.8 : Çalışmada kullanılan U-Net mimarisinin gösterimi.....	31
Şekil 2.9 : Çalışmada kullanılan SegNet mimarisinin gösterimi.....	31
Şekil 2.10 : DeepLab mimarisinin genel gösterimi.	33
Şekil 2.11 : Artık öğrenmenin temel gösterimi.	35
Şekil 2.12 : ResNet mimarileri.	36
Şekil 2.13 : Inception mimari yapısının işleyişine dair gösterim.	38
Şekil 2.14 : Xception mimari yapısının işleyişine dair gösterim.....	38
Şekil 2.15 : Yoğunluk oylama ile semantik segmentasyonun şemasal gösterimi.....	42
Şekil 3.1 : Sentinel veri seti akış diyagramı.	45
Şekil 3.2 : İstanbul test alanı orijinal (sağda) ve referans görüntüleri (solda).	50
Şekil 3.3 : 5-bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32 × 32 görüntü parçacığı; e–h: 64 × 64 görüntü parçacığı; i–l: 128 × 128 görüntü parçacığı).....	50
Şekil 3.4 : 7-bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32 × 32 görüntü parçacığı; e–h: 64 × 64 görüntü parçacığı; i–l: 128 × 128 görüntü parçacığı).....	52
Şekil 3.5 : Kocaeli test alanı orijinal (sağda) ve referans görüntüleri (solda).	56
Şekil 3.6 : Beş bantlı veri setine sahip ESA modelleri ve ESA-ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32 × 32 görüntü parçacığı; e–h: 64 × 64 görüntü parçacığı; i–l: 128 × 128 görüntü parçacığı).	56
Şekil 3.7 : Yedi bantlı veri setine sahip ESA modelleri ve ESA-ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32 × 32 görüntü parçacığı; e–h: 64 × 64 görüntü parçacığı; i–l: 128 × 128 görüntü parçacığı).....	61
Şekil 3.8 : Hata matrisinin genel gösterimi değerleri.	63

Şekil 3.9 : İstanbul test alanı için farklı görüntü boyutlarında kesinlik ve duyarlılık değerleri.....	64
Şekil 3.10 : Kocaeli test alanı için farklı görüntü boyutlarında kesinlik ve duyarlılık değerleri.....	65
Şekil 3.11 : Zurich Summer Veri seti uygulaması akış diyagramı.	66
Şekil 3.12 : Zurich Summer veri seti sonuçları (ZH-16): (a) orijinal görüntü; (b)referans veri; (c–f) 32 × 32 görüntü boyutu; (g–j) 64 × 64 görüntü boyutu; (k–n) 128 × 128 görüntü boyutu.	68
Şekil 3.13 : Zurich Summer veri seti sonuçları (ZH-17): (a) orijinal görüntü; (b)referans veri; (c–f) 32 × 32 görüntü boyutu; (g–j) 64 × 64 görüntü boyutu; (k–n) 128 × 128 görüntü boyutu. ... Error! Bookmark not defined.	
Şekil 3.14 : Sentinel veri setinden bölütleme örnekleri. Kırmızı çizgi referans nesneyi; yeşil çizgi ÇÇB segmentini ifade etmektedir.	75
Şekil 3.15 : Zurich Summer veri setinden bölütleme örnekleri. Kırmızı çizgi referans nesneyi; yeşil çizgi ÇÇB segmentini ifade etmektedir.....	75
Şekil 3.16 : WHUBED veri seti uygulamasının akış diyagramı.....	77
Şekil 3.17 : Orijinal görüntüler ve referans veriler (solda 003 görüntüsü; sağda 055 görüntüsü).....	77
Şekil 3.18 : 003 görüntüsünün DeepLabV3+ ResNet-50 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	78
Şekil 3.19 : 003 görüntüsünün DeepLabV3+ResNet-18 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	78
Şekil 3.20 : 003 görüntüsünün DeepLabV3+Xception sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	79
Şekil 3.21 : 003 görüntüsünün DeepLabV3+Mobilenetv2 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	79
Şekil 3.22 : 055 görüntüsünün DeepLabV3+ResNet-50 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	79
Şekil 3.23 : 055 görüntüsünün DeepLabV3+ ResNet-18 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	80
Şekil 3.24 : 055 görüntüsünün DeepLabV3+Xception sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	80
Şekil 3.25 : 055 görüntüsünün DeepLabV3+Mobilenetv2 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).	80
Şekil 3.26 : DeeplabV3+ mimarisi ile WHUBED veri seti 003 test görüntüsü sonuçları.	82
Şekil 3.27 : DeeplabV3+ mimarisi ile WHUBED veri seti 055 test görüntüsü sonuçları.	82

UZAKTAN ALGILAMA VERİLERİ KULLANARAK DERİN ÖĞRENMEYE DAYALI ARAZİ KULLANIMI VE ARAZİ ÖRTÜSÜ HARİTALAMA MODELİ GELİŞTİRME

ÖZET

Doğal kaynakların gün geçtikçe tükenmesi, nüfus artışı, kentsel göç ve artan kuraklık koşulları çevresel izleme programlarının gerekli olmasının ve düzenli olarak üretilip güncellenmesinin nedenlerinden bazılarıdır. Tüm dünyada olduğu gibi, ülkemizde de pek çok alanda kullanılan arazi kullanımı ve arazi örtüsü (AKAÖ) haritaları düzenli olarak üretilip güncellenmektedir. CORINE sınıflandırmasına dâhil olan ülkemiz hem bu alanda hem de birçok farklı endüstriyel, akademik ve kamu alanları için uzaktan algılama görüntüleri kullanarak tematik harita üretimini gerçekleştirmektedir. Ancak geniş alanlarda uygulandığında bu üretimin oldukça zaman alması hem üretimde hem de güncellemede karşılaşılan zorlukların başındadır. Hala birçok tematik harita, görsel yorumlama teknikleri ve yarı-otomatik görüntü işleme analizleriyle üretilmektedir. Operatör gereksinimi, uzun süren işlemler (ekran üzerinde sayısallaştırma) gibi pek çok nedenden dolayı özellikle çevresel izleme alanındaki kartografik üretimin otomatikleştirilmesi önem arz etmektedir. Otomatikleştirme işlemi birçok diğer endüstride olduğu gibi bu alanda da yapay zekânın kullanımı ile mümkün hale gelmektedir. Ek olarak, yapay zekânın geo-konumsal yer gözlemi ve bölgesel arazi izleme misyonlarında kullanımı zorlu bir konudur. Ancak bilgisayar sistemlerinin gelişmesi ile işlem kolaylığı gün geçtikçe artmaktadır. Aynı zamanda yapay zekânın kullanımının birçok avantajı mevcuttur. Operatör gereksinimini azaltan, farklı bölgelerde uygulanabilen, adapte edilebilen modellere ve belli aralıklarla otomatik şekilde güncellemeye olan ihtiyaç ve eğilim her geçen gün artmaktadır. Birçok alanda olduğu gibi AKAÖ haritalamada, bilgisayarlı görünüm kullanımının hızla arttığı ve son yıllarda yeni birçok tekniğin geliştirildiği bilinmektedir. Bilgisayarlı görü teknikleriyle, son dönem uzaktan algılama yöntemleri birleştirilerek oluşturulan yapay zekâ uygulamaları birçok yönden verim sağlamaktadır. Geniş alanların sınıflandırılmasında uydu görüntülerinin kullanımı, özellikle açık veri paylaşan uyduların da gelişen özellikleri sayesinde çok daha ekonomik ve pratik olabilmektedir.

Bu çalışma kapsamında, derin öğrenme teknikleri kullanılarak farklı detay seviyelerindeki sınıflar için AKAÖ haritaları üretilmiştir. Çalışmalarda veri olarak farklı mekânsal çözünürlüklerde uydu görüntülerinden oluşan üç farklı veri seti kullanılmıştır. Çalışma alanı olarak seçilen bölgelerde görüntülerin semantik segmentasyon (anlamsal segmentasyon) yöntemi ile sınıflandırılmasında evrimsel sinir ağları (ESA) mimarileri kullanılmıştır. Sınıflandırma doğruluğunu yükseltmek ve performans ölçütlerini iyileştirmek için, kullanılan görüntülerin bantlarının yanı sıra ESA mimarilerinde farklı spektral indisler de kullanılarak farklı boyutlarda veri setleri ile sınıflandırma için kullanılan modeller ile eğitilmiştir. Elde edilen sınıflandırma sonuçları üzerinde iyileştirme yapılması amacıyla nesne-tabanlı görüntü analizi

(NTGA) aşamalarından çoklu-çözünürlüklü bölütleme (ÇÇB) algoritmasından yararlanılmış ve konumsal filtreleme yapılmıştır.

İlk uygulamadaki Sentinel-2 veri seti, Türkiye'ye ait mekânsal olarak orta çözünürlüklü görüntülerden oluşmaktadır. Bu uygulamada Sentinel-2A görüntüleri kullanılarak oluşturulan farklı bant kombinasyonu (beş ve yedi bant) ve farklı görüntü parçacığı boyutları (32×32 , 64×64 ve 128×128 piksel) kullanılmıştır. Üç farklı şehre ait görüntülerle oluşturulan veri setiyle AKAÖ haritalama için güncel ESA tabanlı modellerin ve önerilen yaklaşım olan ESA-ÇÇB modelinin aynı bölgedeki sonuçları değerlendirilmiştir. Sentinel veri setinde, en yüksek genel doğruluk, önerilen yaklaşımla İstanbul test alanında % 97.31 ve Kocaeli test alanında % 98.44 olarak elde edilmiştir. Doğruluklar, geniş alanlarda arazi örtüsü haritası üretimi için ESA-ÇÇB modelinin verimliliğini ortaya çıkarmıştır. McNemar testi kullanılarak uygulamada kullanılan modellerin bilimsel olarak anlamlılığı ölçülmüştür.

Benzer yöntemler ikinci uygulamada çok yüksek çözünürlüklü görüntülere sahip Zurich Summer veri setinde uygulanmıştır. Sonuçlar, temel ESA modellerinin sonuçları ile nicel olarak karşılaştırılmıştır. Bu uygulamada, Zurich Summer veri seti ile önerilen yaklaşımın genel doğruluğu % 92.03 ve %90.67 olarak elde edilmiştir. Elde edilen sonuçlar ek olarak literatürdeki diğer modellerin sonuçlarıyla karşılaştırılmıştır.

Üçüncü uygulamada, farklı mekânsal çözünürlükte Wuhan Üniversitesi bina çıkarımı veri setinde (WHUBED) diğer iki uygulamadan farklı derin öğrenme ağları kullanılmıştır. Önerilen yaklaşımın kullanımı, tek başına ESA kullanıldığındaki sonuçlarla karşılaştırıldığında performans değerlerinde iyileştirme yapmıştır. WHUBED veri setinde test görüntülerinde % 97.57 ile % 81.06 genel doğruluk değerleri ve % 86.46 ile % 86.49 F1 skoru elde edilmiştir. Bu uygulamada da temel ESA modellerinin sonuçlarıyla, tezde önerilen yaklaşımın sonuçları karşılaştırılmış ve sonuçlar çizelgeler ve görseller şeklinde sunulmuştur. Bu uygulamada, genel doğruluk ve F1 skor ölçütlerinde önerilen yaklaşım daha yüksek performans göstermiştir.

DEVELOPING A DEEP LEARNING-BASED LAND USE AND LAND COVER MAPPING MODEL USING REMOTE SENSING DATA

SUMMARY

Natural and artificial are in land cover and land use (LULC) classes change over time due to human actions or natural causes. Some of the reasons that cause the conversion of the natural regions to artificial areas are the expansion in the urbanization area, changes in wetlands and agricultural lands, erosion, natural or man-made fires in green areas and losses due to tree cutting. Natural causes that cause land cover/use change include drought and flood events, landslides and terrestrial movements. Monitoring environmental resources and analyzing changes are very important for environmental planning and management. Image processing and classification are preferred and widely used techniques for Earth observation applications. Many institutions and organizations produce LULC and change maps periodically. There are many land cover classification systems developed to date. These systems produce thematic maps at national, regional and global scales, with different levels of detail and classes. These maps are widely used for many applications. LULC maps are developed and updated regularly in many sections of our country and worldwide. As well as many other industrial, academic, and public sectors, our country, which has a member of the Coordination of Information on the Environment (CORINE), generates thematic maps using satellite images. However, this production takes a long time when used in wide areas, which is one of the challenges in both production and updating. Visual interpretation techniques and semi-automatic image processing analysis are still used widely for generating thematic maps.

Automate cartographic production is a need especially in environmental monitoring, due to many reasons such as operator requirement and long process time (on-screen digitization). Automation in thematic map production becomes possible with artificial intelligence in this field, as in many other industries. On the other hand, using artificial intelligence in geospatial Earth observation and regional terrain monitoring missions is challenging. However, the problems encountered are overcome with computer technologies and artificial intelligence finds a wide area of usage. Additionally, there are many advantages of using artificial intelligence. The need for updated and applied models in different regions that reduce operator labor increases day by day. In many areas, it is known that the use of LULC in computer vision has grown rapidly and various techniques have been developed.

Remotely sensed data is used in the classification process in LULC map production for many areas, such as monitoring forest borders, agricultural yield estimation, changing boundaries, land use classes with urbanization, natural disasters, etc. The usage of remote sensing technologies has many advantages, such as being economical, saving time and being more suitable for most conditions (weather, rapid production, updating, etc.). Furthermore, satellite images in the classification of large areas can be

much more economical and practical, mainly due to the developing features of open data-sharing satellites.

Within the scope of the thesis, LULC maps were produced using deep learning techniques at different levels of detail. Additionally, improving the classification with an object-based approach on the estimation results produced using the deep learning (DL) model is also included in the proposed approach. In the studies, three different datasets consisting of satellite images with different spatial resolutions (images of commercial and open data sharing satellites) were used as data. Convolutional neural network (CNN) architectures were used in semantic segmentation of images in the regions selected as the study area. At the same time, several algorithms have been applied to enhance the results in experiments. Object-based image analysis (OBIA) stages and spatial filtering were used to improve ESA models' classification results. In the Sentinel-2 dataset, CNN architectures were rearranged and different spectral indices were produced in addition to the bands of the images used. Thus, data sets of various sizes were generated and the models used for classification were trained.

Three different data sets were used in the experiments. The proposed approach in the thesis was tested on three different data sets. In the first experiment, In the first experiment, a data set generated with Sentinel-2 images of Istanbul, Kocaeli and Muğla provinces of Turkey was used. The results of the CNN-MRS model, the proposed approach for LULC mapping, and the state-of-the-art CNN-based models, were compared with the data set generated with the images of three different cities. In the second experiment, a similar methodology was applied to the Zurich Summer dataset and the results were compared with the results of other models in the literature. In the third experiment, different deep learning networks from the previous two applications were used in the Wuhan Building Extraction Dataset (WHUBED) dataset. Likewise, the results of the other CNN models and the proposed approach in the thesis are compared. The proposed approach showed higher performance as overall accuracy and F1 score metrics in this application.

The proposed CNN-MRS approach consists of two main steps. First, the CNN-based land cover classification follows the development of classification with spatial filter and multi-resolution segmentation (MRS). In applications, the aim is to improve deep learning models' predictions and generate thematic maps with higher accuracy in selected metrics. Different band numbers (5-band and 7-band datasets) and multiple image patch sizes (32×32 , 64×64 and 128×128 pixels) of Sentinel-2A images were used in the first experiment. Algorithms were evaluated with performance metrics. The Sentinel dataset obtained the highest overall accuracy with the proposed approach as 97.31% in the Istanbul test area and 98.44% in the Kocaeli test area. Accuracies revealed the efficiency of the CNN-MRS model for land cover map production over large areas. Mc-Nemar test statistics were calculated for five- and seven-band Sentinel datasets for each image patch size (32, 64, and 128) for state-of-the-art CNNs and proposed approach models. According to Mc Nemar test, dataset H_1 hypothesis is true for all methods of Sentinel-2 dataset; that is, it is significant to compare all methods in the Sentinel dataset experiments.

In the second experiment, the overall accuracy of the proposed approach with the Zurich Summer data set were 92.03% and 90.67%. The results were quantitatively compared with the results of the state-of-the-art CNN model and related studies. Segmentation quality metrics for both datasets are shown in the tables. The suitability of the selected segmentation parameters was checked with the segmentation quality metric.

In the third experiment, the proposed approach with the WHUBED dataset has improved performance values than state-of-the-art CNNs results. The proposed approach obtained 81.06 % overall accuracy and 86.49% F1 score for test area I and 97.57% overall accuracy and 86.46% F1 score for test area II in the WHUBED dataset. The proposed approach has been shown to enhance the predictions of deep learning methods in LULC applications at different semantic levels, thanks to the applications in the thesis. The usability of the proposed model has been proven in models trained in a large area and not a very large area. Also, the proposed approach is feasible for 3-band datasets and more than 3-band datasets in the applications. In the same way, the methods have been applied in the dataset with balanced or imbalanced class distribution, and its usability has been demonstrated.





1. GİRİŞ

Dünya üzerindeki doğal kaynakların sınırlı ve zamanla azalıyor oluşu, insanoğlunun bu kaynakları düzenli şekilde tespit ve takip etmesini zorunlu kılmaktadır. Hızla artan nüfusun ve sanayileşmenin etkisiyle kırsal alandan, kentsel alanlara göç her geçen gün artmaktadır. Dünyanın % 0,1'den daha azını kentleşmiş alanların oluşturmalarına rağmen, dünya nüfusunun yüzde 50'den fazlası da bu alanlarda yaşamaktadır (Lee ve Baik, 2011). Kentsel ekolojik sistemlerin arazi kullanımı ve arazi örtüsü (AKAÖ) haritaları üretecek şekilde periyodik olarak izlenmesi, çevresel izleme, sürdürülebilirlik, kentsel planlama, doğal kaynakların izlenmesi ve sosyo-ekonomik politikaların belirlenmesi açısından oldukça önemli bir uygulamadır. Arazi kullanımı (AK) ve arazi örtüsü (AÖ), kentsel planlama ve çevresel izleme için kullanılan birbirini tamamlayan iki kartografik bilgidir (Rousset ve diğ, 2021). Arazi izleme, dünyadaki AKAÖ hedeflerinin en önemli odak noktalarından biridir.

AKAÖ tespit ve takip için dünya çapında farklı teknikler mevcuttur. Yer gözlemi çalışmaları genellikle oldukça geniş alanları kapsamaktadır. Geniş alanlarda takibin uygulanması ve periyodik olarak tekrar edilmesi için sağlam, verimli ve ekonomik tekniklerin kullanılması gerekmektedir. Son yıllarda giderek önem kazanan uzaktan algılama teknolojileri arazi izleme ve takibi için önemli imkânlar sağlamaktadır. Uzaktan algılanan verilerin birçok alanda ve araştırmalarda kullanımı özellikle son yıllarda oldukça yaygınlaşmıştır. Uzaktan algılama verileri ile hem tematik hem de topografik haritalar üretmek mümkündür. Uzaktan algılama teknolojileri, farklı ölçeklerde çevresel izleme için tüm dünyada yaygın olarak kullanılmaktadır. Kentsel büyüme, kırsal alanlardaki ve orman alanlarındaki değişimler ve açık alanlar bölgesel izleme hedefleri altında sayılabilecek konulardan bazılarıdır.

Yer yüzeyinde bulunan özelliğin türü (fiziksel özellikler veya malzemeler) arazi örtüsü olarak adlandırılır. Su, kum, patates ürünü veya asfalt, arazi örtüsünün bazı örnekleridir (Tempfli ve diğ, 2009). Arazi kullanımı, arazi üzerinde doğal olarak bulunan alanların nasıl kullanıldığını; örneğin konut ve/veya sanayi alanları, insanın yeryüzü ile etkileşimiyle oluşan arazi kullanım sınıflarıdır (Sunar ve diğ, 2018).

Zamanla, insan etkisiyle veya doğanın dönüşümüyle AKAÖ sınıflarında değişiklikler meydana gelir. AKAÖ sınıflarının bir kısmı doğal alanlardan oluşurken, bir kısmı da yapay alanlardan meydana gelmektedir. Doğal alanların yapay alanlara dönüşmesine neden olan sebeplerden bazıları, kentleşme alanındaki genişleme, sulak alanlarda ve tarım arazilerinde meydana gelen değişiklikler, erozyon, yeşil alanlarda doğal veya insan kaynaklı yangınlar ve ağaç kesimlerinden kaynaklanan kayıplardır. Değişimler insan kaynaklı olabildiği gibi, doğal kaynaklı da olmaktadır. Arazi örtüsü/kullanım değişikliğine neden olan doğal sebepler arasında heyelanlar, karasal hareketler, kuraklık ve sel hadiseleri sayılabilir. Çevresel kaynakları izlemek ve değişiklikleri analiz etmek, çevresel planlama ve yönetim için oldukça önemlidir. Yer gözlem uygulamaları olarak görüntü işleme ve sınıflandırma tercih edilen tekniklerin başında yer almaktadır. Bu bağlamda, bölgesel izleme programları yaygın olarak kullanılmaktadır. Birçok kurum ve kuruluş AKAÖ ve değişim haritalarını periyodik olarak üretmektedir. Bugüne kadar geliştirilmiş çok sayıda arazi örtüsü sınıflandırma sistemi bulunmaktadır. Farklı detay seviyelerinde ve sınıflarda olmak üzere bu sistemler ulusal, bölgesel ve küresel ölçeklerde tematik haritalar üretmektedirler. Bu haritalar çok sayıda uygulama için yaygın biçimde kullanılmaktadır. Coordination of Information on the Environment (CORINE) Programı ve sınıflandırma sistemi, Birleşmiş Milletler Jeoloji Araştırmaları Kurumu (USGS) ulusal arazi örtüsü veri tabanı (hidroloji, orman olarak bitki örtüsü, Grönland, tarım, yenilenebilir enerji kaynakları gözlemleri ve sürdürülebilirlik çalışmaları) ve USGS Arazi Örtüsü Enstitüsü (LCI) bu haritalara örnek olarak verilebilmektedir. Bunların yanı sıra diğer ilgili sistemler arasında Avrupa Uzay Ajansı, Gıda ve Tarım Örgütü (FAO) gibi kurumlar ve Copernicus, Urban Atlas, Africover gibi programlar örnek olarak sayılabilir. Bu organizasyon ve kurumlar AKAÖ haritaları için birbirinden farklı ölçeklerde ve çeşitli mekânsal-zamansal yaklaşımlarda coğrafi bilgi sistemleri (CBS) ve uzaktan algılama (UA) tekniklerini kullanır. Kullanılacak olan tekniğin seçimi sınıflandırılmak istenen sınıfların detay seviyesine ve türüne bağlı olarak da farklılıklar içermektedir.

Çevresel izleme, sürdürülebilirlik, şehir planlaması, doğal kaynakların izlenmesi ve sosyo-ekonomik politikaların belirlenmesi için AKAÖ haritalarının periyodik olarak üretilmesi esastır. Bu periyotlar yıllar geçtikçe, tematik haritaların kullanım alanlarının da genişlemesi ve gelişen teknolojinin etkisiyle daha sık hale gelmektedir. Buna örnek

olarak, CORINE üretim hızı verilebilir. İlk zamanlardaki üretim aralığı, yıllar geçtikçe kısalmaktadır. Bu durum beraberinde işlemlerin otomatikleştirme (ya da yarı-otomatikleştirme) ve birden fazla bölgeye, alana, sınıf seviyesine uyarlanabilen, doğruluğu yeterli düzeyde olan modellerin geliştirilmesi ihtiyacını da artırmaktadır. Ancak, halen bazı çevresel izleme uygulamalarının üretim tekniği uydu görüntülerinin ekran üzerinde sayısallaştırılmasına dayanmaktadır. Bu tarz operatöre dayalı bir uygulamanın oldukça uzun zaman alması ve operatör kullanımından kaynaklı hatalara açık olması gibi dezavantajları mevcuttur.

Dünyanın arazi örtüsü, tatmin edici bir doğruluk değerlendirmesi ile sınıflandırmak için karmaşık bir yapıdır. Bu alanda sağlam, etkili ve hızlı yöntemleri sistematikleştirmek oldukça önem arz etmektedir. Bu nedenle, her geçen yıl AKAÖ haritalarını üreten sistemler (Copernicus, Avrupa Uzay Ajansı, Alman Havacılık ve Uzay Merkezi (DLR) gibi) tekniklerini daha otomatikleştirmenin ve yapay zekâ tekniklerini de sisteme dâhil etmenin yollarını aramaktadırlar. Bilgisayarlı görünün alt kollarında olan bu teknikler, klasik görüntü işleme tekniklerinin yanında kendine gittikçe daha geniş yer bulmaya başlamıştır (Vali ve diğ, 2020). Dijital görüntü işleme ve bilgisayarla görü uygulamalarında dünya çapında uzaktan algılanan verileri kullanılması oldukça yaygındır. Birçok endüstride olduğu gibi, bu alanda da derin öğrenme (DÖ) tekniklerinin kullanımına yer verilmeye başlanmıştır. Vali ve diğ. (2020) çalışmasına göre, 2015 yılından sonra AKAÖ sınıflandırması için derin öğrenme tekniklerinin kullanımı hızla artış göstermektedir. Bu çalışmalarda çoklu-spektral ve/veya hiper-spektral görüntüler kullanılmaktadır. Ayrıca, öğrenme tabanlı uygulamalar, aşamaların bir kısmının otomatikleştirilmesi için uygundur. Birçok başka endüstri ve uygulama alanında olduğu gibi, yapay zekâ ile olan uygulamaların periyodik olarak yapılması, insan gücü ve zaman tüketimi konusunda etkili bir yol olarak karşımıza çıkmaktadır.

Hızla değişen yeryüzü kullanımıyla beraber sürekli yenilenebilen, etkili bir model ile yer izlemenin önemi bilinmektedir. Bu nedenle, tez kapsamında da yukarıda bahsedilen birçok ihtiyaca yönelik olarak, derin öğrenme tabanlı tematik harita üretimini sınıflandırma doğruluğu açısından iyileştiren aşamalara sahip bir yaklaşım önerilmiştir. Tez çalışmasında farklı mekânsal çözünürlüklere sahip ve farklı sınıfları içeren uzaktan algılama görüntüleri kullanılmıştır. Önerilen yaklaşımın ilk uygulamasında Sentinel-2A uydu görüntüleri kullanılarak Türkiye’de iki farklı şehre

ait AKAÖ haritaları üretilmiştir. Sentinel-2 veri seti kullanılarak gerçekleştirilen uygulamada uydu görüntüsünün spektral bantlarına ilave olarak yardımcı veriler (spektral indisler) de kullanılmıştır. İlk uygulamada, AKAÖ haritalarının üretilmesinde DÖ modeli olarak U-Net (Ronneberger ve diğ, 2015) ve SegNet (Badrinarayanan ve diğ, 2017) mimarileri seçilmiştir. Ek olarak, DÖ tahmin çıktılarını iyileştirmek için NTGA ile üretilen bölütlemelerden faydalanılmıştır. Hedeflenen sınıflar yapay alanlar, yarı doğal alanlar ve su yapıları olarak belirlenmiştir. Çalışma bölgesi olarak İstanbul, Kocaeli ve Muğla illeri seçilmiştir. İkinci uygulamada birincisine benzer DÖ yöntemleri ile AKAÖ haritaları üretilmiştir. Bu uygulamada veri seti olarak birçok uygulamada performans karşılaştırmalarında temel veri seti olarak kullanılan 0.61m çözünürlüklü uydu görüntülerinden oluşan Zurich Summer veri seti (Volpi ve Ferrari, 2015) kullanılmıştır. Bu veri setinde daha yüksek detay seviyesinde sınıflar mevcuttur. Görüntüler kullanılarak yol, bina, ağaç, çimen, çıplak toprak, su, demiryolu ve yüzme havuzu olmak üzere 8 sınıfın çıkarılması hedeflenmiştir. Elde edilen sonuçlar literatürde bulunan popüler derin öğrenme yöntemleri ile karşılaştırılmıştır. Üçüncü uygulamada iki sınıflı sınıflandırma problemi ele alınmıştır. Bu uygulamada değerlendirmeye alınan arazi kullanım sınıfları bina ve bina-olmayan şeklindedir. Veri seti olarak literatürde değerlendirmeye alınan WHUBED veri seti (Bi ve diğ, 2019) kullanılmıştır. Söz konusu veri seti üç farklı mekânsal çözünürlüklü (0.5-1 m arasında) Quickbird, Wordview-2 ve Gaofen-2 uydu görüntülerinden oluşmaktadır. Bu uygulamada diğer uygulamalardan farklı olarak dört farklı derin öğrenme modeli uygulanmıştır. Elde edilen sonuçlar NTGA tabanlı yöntemle ve filtreleme ile iyileştirilmiştir. Bütün uygulamalardaki deneylerin sonuçları literatürdeki yaygın değerlendirme ölçütleri kullanılarak sunulmuştur. Uygulamalarda kullanılan değerlendirme ölçütleri genel doğruluk, ortalama doğruluk, ağırlıklı doğruluk, kesinlik, duyarlılık, F1 skoru ve kappa istatistik değeridir. Sonuçlar çizelgeler ve grafikler halinde sunulmuştur. Bu uygulamalar sayesinde temel karşılaştırma veri setleri kullanılarak önerilen yaklaşımın geçerliliği analiz edilmiştir.

1.1 Tezin Amacı

Tez çalışmasında, farklı detay seviyesindeki sınıflar için uzaktan algılama görüntüleri kullanılarak derin öğrenme tabanlı sınıflandırma ile AKAÖ haritalarının oluşturulması amaçlanmıştır. Tematik haritaların üretim sürecinde zaman, işlem ve performans

konularında verimlilik artırılması istenmiştir. Farklı detay seviyelerinde arazi kullanımı ve örtüsü sınıflarını semantik segmentasyon ile çıkartmak amacıyla farklı mekânsal çözünürlükte görüntüler kullanılmıştır. Yüksek çözünürlüklü ve orta çözünürlüklü uydu görüntüleri yardımıyla; farklı AKAÖ seviyesi sınıflarını içeren tematik harita üretimi gerçekleştirilmiştir. AKAÖ haritaları günümüzde eskiye nazaran daha sık periyotlarla geniş alanlar için üretilmektedir. Ancak bu üretimin aşamalarını insan operatörünün görüntü yorumlaması ve görüntü işleme analizleri ile yarı-otomatik yöntemler oluşturmaktadır. Bu yöntemler harita üretiminde hem uzun süreler almakta hem de insan kaynaklı hataların daha sık olmasına yol açmaktadır.

Derin öğrenme yaklaşımları semantik segmentasyonda bazı durumlarda sınıfların homojen olarak çıkartılmasında yetersiz kalabilmektedir. Bunun temel nedeni spektral benzerliklerden dolayı sınıflar arasında karışıklıklara rastlanmasıdır. Bu durum tematik haritalarda gürültü olarak tanımlanmaktadır. Derin öğrenme çıktılarının doğruluğunun iyileştirilmesi için tez kapsamında nesne tabanlı görüntü işleme ve filtreleme yaklaşımı uygulanmıştır. Çalışmadaki uygulamalarda, ESA modelleri ile semantik segmentasyona ek olarak, NTGA yöntemi ile elde edilen bölütlemeler kullanılmıştır. NTGA bölütünün içine düşen piksellerin belirli oranda yoğunluğuna bakılarak, ilgili bölütün bütün pikselleri bu şekilde belirlenen yoğunluk sınıfına atanmıştır. Böylece derin öğrenme tekniklerinin sonucunda oluşabilecek gürültülerin de giderilerek semantik segmentasyon doğruluğunun arttırılması amaçlanmıştır.

Tez kapsamında önerilen yaklaşım, bu çalışma için oluşturulan veri setinde farklı şehirlerden (bölgelerden) seçilen görüntülerde eğitilmiş ve test edilmiştir. Muğla ve İstanbul şehirlerinde eğitilen model, Kocaeli ve İstanbul'da test edilmiştir. Bu iki testin sonuçları da bilimsel bağlamda karşılaştırılarak incelenmiştir. Böylece modelin farklı alanlara adapte edilebilirliği araştırılmıştır. Çalışmadaki yaklaşımın avantajlarını ve sınırlamalarını göstermek için, önerilen yaklaşım, üç farklı uygulamada çeşitli deneylerle ve farklı çözünürlüklü görüntülerden oluşan veri setleri üzerinde uygulanmıştır. Ayrıca, bu uygulamalarda sınıflandırılan sınıflar bakımından da, farklı detay seviyelerinde AKAÖ sınıfları için tez kapsamında önerilen yaklaşım uygulanmıştır. Uygulamalarda iki-sınıflı ve çok-sınıflı semantik segmentasyon uygulaması gerçekleştirilmiştir. Bununla beraber, iki uygulamada derin öğrenme modellerine girdi olarak farklı boyutlarda görüntü parçacıkları kullanılarak, kullanılan DÖ modelleri için optimum (uygun değer) boyutları da aranmıştır.

Çalışma kapsamında değerlendirmeye alınan Sentinel-2 veri setinde farklı bant ve vejetasyon indisleri ile aynı bölgeye ait farklı boyutta (bant sayısı) veri setleri oluşturulmuştur. Bu sayede, uzaktan algılama görüntü işleme tekniklerinin avantajları (spektral indisler ile bilgi çıkarımı) da önerilen modelde uygulanması amaçlanmıştır. Bilgisayarlı görü alanında sıkça tercih edilen üç bant kombinasyonu kullanımına da alternatif olarak uygulanan bu uygulamalarda, üç banttan daha fazla bant sayısı DÖ modeline girdi verisi olarak uygulanmıştır. Bu sayede, derin öğrenme uygulamalarında alana dair uzman bilgisi de uygulamaya katılması amaçlanmıştır. Bu amaçla, kullanılacak derin öğrenme mimarileri üzerinde uygulamada kullanılacak veri setlerini işlemek için gerekli düzenlemeler yapılmıştır.


Aynı zamanda, Sentinel-2 ve Zurich Summer veri setlerinde kullanılan iki farklı gelişmiş DÖ modeline ek olarak, WHUDEB veri setinde diğer veri setlerinden farklı dört adet güncel (state-of-the-art) derin öğrenme modeli kullanılmıştır. Böylece tez kapsamında önerilen yaklaşımın sadece belirli derin öğrenme mimarilerinde değil, birçok DÖ ağ yapısında da uygulanabilirliği araştırılmıştır. Bu amaçlar doğrultusunda, AKAÖ sınıflandırma yaklaşımı geliştirilmiş ve tez kapsamında üç farklı veri setinde, geliştirilen model uygulanarak sonuçlar literatürde yaygın kullanılan performans ölçütleri yardımıyla niceliksel olarak ortaya konmuştur.

1.2 Yöntem

Tez çalışmasında, Sentinel-2, Zurich Summer ve WHUBED veri setleri kullanılarak farklı detay seviyelerindeki sınıflar için AKAÖ üretilmiştir. İlk uygulamada Sentinel-2 verileri kullanılmıştır. Bu uygulamada, çalışma alanı Türkiye'deki İstanbul, Muğla ve Kocaeli illerinden seçilmiştir. Semantik segmentasyon için bu uygulamada Sentinel-2A görüntüleri kullanılmıştır. Veri setinde Sentinel-2A bantları ve bantlardan üretilen spektral indeksler birleştirilmiştir (layer-stack). Böylece bu deneyde iki farklı bant kombinasyonuna sahip veri seti kullanılmıştır. İlk veri seti beş bant (R, G, B, NIR ve NDVI) içermektedir. İkinci veri seti yedi bant (R, G, B, NIR, NDVI, SR ve DVI) içermektedir. Ayrıca derin öğrenme esnasında kullanılan görüntü parçacığı boyutunun (patch-sizes) sınıflandırmaya etkisi de incelenmiştir. Bu uygulama sonrasında, uygulamada kullanılan modellerin bilimsel olarak anlamlılığı McNemar testi ile gösterilmiştir.

İkinci deneyde, ESA-ÇÇB modeli Zurich Summer açık (public) veri setine uygulanmıştır. Deneyin sonunda, Zurich veri setinin sonuçları temel ESA modelleriyle karşılaştırılmıştır. Ayrıca kullanılan DÖ modellerine girdi olarak kullanılan görüntü parçacığı boyutunun sınıflandırmaya etkisi incelenmiştir. Deneylerde 32×32 , 64×64 ve 128×128 piksel görüntü parçacığı kullanılmıştır. Sonuçlar çizelgeler ve arazi örtüsü haritaları şeklinde gösterilmiştir.

Üçüncü uygulamada WHUBED veri setinde önerilen yaklaşım ile elde edilen sonuçlar yine sadece derin öğrenme kullanılarak yapılan tahminlerden daha yüksek doğruluklu sonuçlar vermiştir. Bu uygulamada bina ve bina dışındakiler şeklinde iki sınıf vardır. Uygulamada sınıflandırılması hedeflenen bina sınıfıdır. Arazi kullanımında oldukça detay bir sınıf uygulamasıyla, modelin birbirinden çok farklı detay seviyelerinde çalışabilirliği test edilmiş ve uygunluğu gösterilmiştir. Şekil 1.1’de tez uygulamasının genel akış şeması sunulmaktadır.




Şekil 1.1 : Tez çalışmasının genel akış diyagramı.

1.3 Uzaktan Algılama Alanında Derin Öğrenme Uygulamaları

Yapay zekâ, bilgisayarlı görü ve görüntü işleme için yeni teknikler ve avantajlar sunar. Büyük veriler için işleme kolaylığı sağlaması ve operatöre dayalı işlemleri azaltması nedeniyle DÖ tekniklerinin kullanımı görüntü işleme alanında hızla artmaktadır. Buna rağmen DÖ birçok endüstride hala yeni bir alandır ve zaman içinde daha da gelişme potansiyeline sahiptir. Kullanım alanları arasında, uzaktan algılama verilerinin arazi kullanımı sınıflandırması da mevcut olup, bu alanda büyük bir potansiyele sahiptir. Literatürde optik ve hiperspektral verilerin kullanımı AKAÖ için DÖ kullanımının

zaman içinde nasıl geliştiğine dair araştırma mevcuttur. Bu çalışmada son 5 yılda yöntem olarak DÖ algoritmalarının kullanımını Vali ve diğ. (2020) Scopus veri tabanında tarama sonuçlarını incelemiştir (Şekil 1.2). Bu araştırma da DÖ'nün bu alandaki büyük ve hızla gelişen potansiyelini yansıtmaktadır.



Şekil 1.2 : Uzaktan algılama verileriyle AKAÖ hakkında beş yıllık aralıklarla Scopus veri tabanındaki trendler (Vali ve diğ, 2020).

Son yıllarda, uzaktan algılama uygulamalarında DÖ kullanımı için çok sayıda model ve veri seti ortaya konmuştur. Birçok ESA modeli, hava fotoğrafları ve uydu görüntüleri gibi yer gözlem verilerinin işlenmesi için kullanılmaktadır. DÖ algoritmaları bu çalışmalarda, yapay çok katmanlı sinir ağı yapısının eğitilmesi sayesinde isabetli tahmin yapmayı öğrenir. Uzaktan algılama görüntüleri aracılığıyla DÖ uygulamaları, nesne algılama, sınıflandırma ve segmentasyon altında gruplandırılabilir (Atik ve İpbüker, 2021a). Tek bir uygulamada bu görevlerden biri veya birkaçı da bir arada olabilmektedir. Nesne tespiti ve segmentasyon bir arada, aynı görüntüler üzerinde yapılabilir (Atik ve İpbüker, 2020). Örneğin uydu görüntülerinden gemi tespiti uygulamasında hem gemiyi obje olarak tespit edip, hem de tespit edilen gemiler instance (örnek) segmentasyon yapılabilir (Atik ve İpbüker, 2021b) (Şekil 1.3). Örnek segmentasyonu için Mask-R CNN (He ve diğ, 2017) yöntemi literatürde öne çıkan yöntemlerden biridir. Nesne tespitinin segmentasyondan farkı tespit edilen sınıfa ait nesnenin kendi sınırları görüntünün diğer bölgelerinden

ayrılmasıdır. Birbiriyle alakası olmayan pikseller nesne tespitinde, sınırlayıcı kutunun (bounding box) içinde kalabilmektedir. Segmentasyonda amaç, tespit edilen nesnenin sınırlarını da belirleyerek, bu sınırların içindeki grup pikseli sınıflandırmaktır.




Şekil 1.3 : Nesne tespiti ve örnek segmentasyon uygulaması – Otomatik gemi çıkarımı (Atik ve İpbüker, 2021b).

Uygulamalarda segmentasyon yaygın olarak üç farklı türde gerçekleştirilmektedir. Bunlar, örnek segmentasyonu (instance segmentation), panoptik segmentasyon ve semantik segmentasyondur. Bu türlerin örnekleri Şekil 1.3 ve Şekil 1.4’de gösterilmiştir.




Şekil 1.4 : Sol semantik segmentasyon, sağ instance (örnek) segmentasyon (Atik ve İpbüker, 2020).




Şekil 1.5 : Segmentasyon türleri (Eppel ve Aspuru-Guzik, 2019).

Ma ve diğ. (2019) tarafından yapılan bir çalışmada uzaktan algılama alanında derin öğrenme uygulamalarının sınıflandırılması yapılmıştır. Bu sınıflandırma Şekil 1.6’de gösterilmiştir.



Şekil 1.6 : Uzaktan algılamada derin öğrenmede dört temel görev (Ma ve diğ, 2019).

Segmentasyon dışında diğer bir DÖ uygulaması görüntü sınıflandırmasıdır. Burada görüntüler genellikle farklı AKAÖ sınıflarına ait küçük parçalar ile eğitilen modeller, yeni görüntülerin hangi arazi sınıflarını içerdiğini tahmin etmektedir. Bu sınıflandırma da kendi içinde üçe ayrılır (Şekil 6). Bunlar tekil (binary), çoklu-sınıf (multi-class) ve çoklu-etiket (multi-label) sınıflandırmalarıdır.



Şekil 1.7 : Tekil, çoklu sınıf, çoklu etiketli sınıflandırma çeşitleri (Atik ve İpbüker, 2020b).

1.4 Arazi Kullanımı ve Arazi Örtüsü Sınıflandırmasında Uzaktan Algılama Teknolojilerinin Kullanımı

Farklı ülkelerde, kuruluşlarda, kurumlarda ve akademide çeşitli AKAÖ sınıflandırma sistemleri kullanılmaktadır. Bilindiği üzere, son yıllarda birçok farklı algılayıcı ile çok

yüksek çözünürlüklü (ÇYÇ) (1 metreden daha az mekânsal çözünürlük) görüntüler elde edilmeye başlanmıştır. ÇYÇ birçok çalışma alanında kullanılmaktadır; yaygın kullanılan alanlardan biri de arazi örtüsü/kullanım sınıflandırma sistemleridir. Yüksek çözünürlüklü verilerin ortaya çıkışı ile bu verilerden bilgi çıkarımını sağlayacak yöntemler de beraberinde hızla geliştirilmektedir. Aynı zamanda, gelişen teknoloji ve artan hesaplama kapasitesi yardımıyla birçok farklı veri kaynağının verimli bir şekilde kullanılarak analiz edilmesine ve görüntü yorumlama, coğrafi bilgi çıkarımı ve görüntü işleme için yeni yöntemler geliştirmesine olanak sağlamaktadır (Dönmez ve İpbüker, 2018).

Piksel gruplarının benzer spektral, renk ve komşuluk özelliklerini kullanarak daha yüksek doğruluk için nesne tabanlı görüntü analiz teknikleri tercih edilmektedir. Her ne kadar ÇYÇ görüntülerin kullanımı yaygın olsa da geniş alanlardaki çalışmalar için, ticari olmayan, görüntüleri açık paylaşılan uydu görüntüleri tercih edilebilmektedir. Bu duruma örnek olan Sentinel uydusu ücretsiz görüntü indirme imkânı sayesinde kullanımı dünyaca yaygınlaşmıştır. Görüntüleri açık paylaşılan bu uydunun görüntüleri LANDSAT uydu görüntüleriyle karşılaştırıldığında, daha yüksek mekânsal çözünürlük sunmaktadır. Sentinel uydu görüntüleri farklı seviyelerde AKAÖ sınıflandırması ve daha birçok tematik harita üretiminde tercih edilmektedir. Daha farklı ölçekte çalışmalar için diğer birçok uydu görüntüsü de kullanımı devam etmekte, uzaktan algılama alanının uygulama alanları birçok endüstride genişlemeye devam etmektedir. MODIS, Terra (ASTER), LANDSAT, ALOS (PALSAR) diğer ücretsiz görüntü paylaşan ve yaygın olarak tercih edilen uydulardan bazılarıdır.

Kullanılan verinin özelliği (uydu görüntüsünün çözünürlüğü, ücretsiz ve periyodik erişim imkânı vb.), sınıflandırma için seçilen sınıfların detay seviyesi (örneğin CORINE, Anderson vb. sınıflandırma sistemi hiyerarşisi), son kullanıcının bilgi seviyesi (uzman kişi ya da vatandaş oluşu) üretilecek AKAÖ haritalarının hangi seviyede olacağıyla ilgili parametrelerden sadece bir kaçıdır. Tematik haritalar, kullanıcının ihtiyacına yönelik şekilde dizayn edilerek üretilir. Tematik haritaların, topografik haritalar kadar net standartları olması yerine, ölçeği, içerdiği sınıf sayısı ve sınıfları, detay seviyesi ihtiyaç ve kullanıcı kitlesi doğrultusunda belirlenebilir. Bu nedenle günümüzde birçok farklı organizasyon ve kuruluş AKAÖ haritaları için kendi standartlarını belirlemiştir. Birçok çalışmada farklı veri kaynağı tercih edilmekle beraber, üretim tekniğinde de değişiklikler söz konusudur. Son dönemlerde, gelişen

teknolojiyle ve görüntü işleme yöntemleri yardımıyla, bölgesel AKAÖ haritaların üretim süresi kısaltmakta ve operatörün zaman ve iş yükü de azaltılması planlanmaktadır. Tüm bu süreçler göz önüne alındığında günümüzde AKAÖ haritaları bazı standartlara sahip olmaya başlasa da, bölgenin, kullanıcının ihtiyacına yönelik üretim esnasında ve ürünün özellikleri açısından pek çok farklılık içermektedir.

39 ülke ile Çevre Arazi Örtüsü ile ilgili Bilgilerin Koordinasyonu (CORINE), USGS'nin USGS Arazi Değişikliği İzleme, Değerlendirme ve Projeksiyon (LCMAP) 1985-2017 yılları arasındaki ABD için Birincil Arazi Örtüsü mozaigi gibi ürünleri Gıda ve Tarım Örgütü (FAO) ürünleri ve AfriCover projesi, AKAÖ ürünlerini sistematik olarak üreten örneklerdir. Son on yıl içinde bu çalışmalarda Arazi Örtüsü Sınıflandırma Sistemi için otomatik veya yarı otomatik yöntemler kullanılmaya başlamaktadır. Bununla birlikte, geniş alanlara veya bölgelere yönelik uygulamalar, üreticiler için hala bir zorluk teşkil etmektedir. Bu nedenle, süreçlerin otomasyonunun arttırılması, AKAÖ prosedürü için zaman ve insan emeği tüketimini azaltmada etkili bir yoldur. AKAÖ üretim süreleri son yıllarda azalmaktadır. CORINE arazi örtüsü – CORINE Land Cover (CLC) 1990 üretim süresi 10 yıl, CLC 2006 3 yıl ve CLC 2018 1.5 yıldır (Lee ve Baik, 2011). Her ürünün üretim teknikleri ve standartlarında benzerlikler ve farklılıklar bulunmaktadır. Bununla birlikte, birçok veri tabanı, AKAÖ harita üretiminde görsel yorumlama ve/veya ekrandaki sayısallaştırma tekniklerini kullanır. USGS, 1: 250.000 ölçeğe (Loveland ve diğ, 1991) görsel analiz yoluyla hava fotoğraflarını kullanarak Anderson Seviye II AKAÖ verilerini üretir. Büyük Britanya CLC Haritası (CLCMGB), genelleme prosedürünü kullanarak arazi kullanım sınıflarını tanımlar ve bu ürünler, arazi kullanımı hakkında önemli miktarda yardımcı bilginin kullanılmasının yanı sıra geleneksel görsel görüntü yorumlama teknikleri kullanılarak elde edilir (Brown ve diğ, 2002). Son zamanlarda, AKAÖ adımlarının üretilmesinde yarı otomatik ilerleme girişimleri vardır. Bronge ve Näslund-Landenmark (2002), sulak alan sınıfları için yarı otomatik etkileşimli bir yaklaşım kullanmıştır. Bu yaklaşım ayrıca İsveç CORINE Arazi Örtüsü – Corine Land Cover (CLC) haritası üretimi için de kullanılmıştır (Bronge ve Näslund-Landenmark, 2002). Teknolojinin gelişmesiyle AKAÖ haritası üretim süreçleri daha verimli hale gelmektedir.

Bölgesel izleme programlarında karar vericiler için zaman ve periyodun güncellenmesi, yer gözlem ve tespiti, çevre çalışmaları ve sürdürülebilirlik konuları,

afet çalışmaları ve ilgili önlemler vb. konuları için oldukça önemlidir. Birleşmiş Milletler Sustainable Development Goals (SDGs) (Şekil 7) takip ve tespit uygulamaları da uzaktan algılamanın kullanım alanlarındadır. Bu bağlamda; “zero hunger”, “industry, innovation and infrastructure”, “sustainable cities and communities” gibi daha birçok hedefte uzaktan algılama çalışmaları yer almaktadır. Küresel izlemenin olduğu bu çalışmalarda genişleyen bölgeler için derin öğrenme kullanımı büyük kolaylıklar sağlamaktadır.



Şekil 1.8 : Birleşmiş Milletler SGD Amaçları (URL-1).

1.5 Literatür Araştırması

Geçmişte arazi örtüsü haritalarının yapım yöntemi, doğruluğu ve verileri mevcut çalışmalardan farklıydı. Örneğin Amerika Birleşik Devletleri için Ulusal Arazi Örtüsü Veri tabanı 1992 (NLCD 1992) oluşturulurken çok zamanlı Landsat TM kullanımı mevcuttur. NLCD 2001'de %74 ile %85 genel doğruluk aralığında denetimsiz bir sınıflandırma yöntemi kullanmıştır (Pekkarinen ve diğ., 2009). CLC 1990, 2000, 2006 ve 2012'de 50 ile 25 m arasında geometrik doğrulukta uydu verileri kullanılmıştır. CLC 2018'de ilk olarak Sentinel-2 görüntüleri $\geq$ %85 tematik doğrulukla kullanıldı. CLC, ülkelerin çoğunluğu tarafından görsel bir yorumla üretilmektedir (URL-2). Son ürünlerde, arazi (in-situ) verileri kullanılarak, CBS ile sayısal görüntü işlemenin birleştirilmesi ve birkaç ülke tarafından genelleme yapılarak yarı otomatik çözümler uygulanmaya başlanmıştır.

Yapılan birçok çalışma derin öğrenme yaklaşımları, AKAÖ tematik haritalarını üretimini çok sınıflı segmentasyon uygulamaları ile yapıldığını göstermektedir. Son on yılda, derin öğrenme yaklaşımı uydu görüntüleri kullanılarak arazi örtüsü sınıflandırması için güçlü bir yöntem olarak ön plana çıkmıştır (Heryadi ve Miranda, 2019). Arazi örtüsüne dayalı çevresel izleme için uydu görüntülerinin ESA'larla semantik segmentasyonu yapılmıştır. Kentleşme (Qin ve diğ, 2019) ve gecekond alanları (Wurm ve diğ, 2019), ormancılık ve bitki örtüsü (Neves ve diğ, 2020), heterojen AKAÖ sınıfları (Yao ve diğ, 2019) ve jeo-konumsal yapay zeka (geoAI) uygulamaları dahil olmak üzere derin öğrenme kullanılan birçok görev ve uygulama vardır. Deep Globe (Demir ve diğ, 2018) ve Big Net Earth (Sumbul ve diğ, 2019) gibi çeşitli yarışmalarda da kullanılan segmentasyon çalışmaları için kullanılan bazı büyük veri kümeleri mevcuttur. AKAÖ sınıflandırma doğruluğunu artırmak için Kaggle ve Crowd Analytix gibi platformlarda görüntü sınıflandırması için çok sayıda yarışma mevcuttur. Öte yandan, U-Net ve U-CAM gibi, orta büyüklükteki veri setleri kullanılarak %85'in üzerinde segmentasyon doğruluğunun elde edilebildiği yöntemler de literatürde mevcuttur (Wang ve diğ, 2020).

2 Boyutlu birçok görüntü segmentasyonu (image segmentasyonu) veri seti mevcuttur. Bu veri setleri kullanılarak literatüre geçmiş birçok derin öğrenme tabanlı algoritma geliştirilmiştir. Bu derin öğrenme mimarileri, uzaktan algılama verileri üzerinde semantik segmentasyon işlemleri için de kullanılabilir. Semantik segmentasyon için kullanılan algoritmalarından bazıları Fully Convolutional Networks (FCN) (2015), visual geometry group (VGG 16) (2014), CNN+CRF (2014), Dilated ConvNet (2015), U-Net (2015), SegNet (2016), DeepLabV3 (2017), Dense-ASSP (2018), HRNet (2019) ve DC-NAS (2020) şeklindedir (Minaee ve diğ, 2021).

Pixel-tabanlı segmentasyon (pixel-wise segmentation) çalışmaları, Fully Connected Networks (FCN), (Long ve diğ, 2015), ve diğer kodlayıcı-kod çözücü (encoder-decoder) tabanlı ağlar (Noh ve diğ, 2015) şeklinde gerçekleştirilebilmektedir. Bu sayede görüntünün her bir pikseli için model kullanılarak bir tahmin değeri üretilir. Ayrıca bu kapsamda, SegNet (Badrinarayanan ve diğ, 2017) ve U-Net (Ronneberger ve diğ, 2015) de kodlayıcı-kod çözücü ağlarına örnekler olarak gösterilebilir ve bu modeller tüm parametrelerin ham veriden sonuç çıktıya öğrenilmesini içerir. Bilgisayarlı görü alanında bu problem (task) semantik segmentasyon olarak

geçmektedir. FCN mimarisini arazi örtüsü için kullanan birçok çalışma (Ma ve diğ, 2019; Zhu ve diğ, 2017) mevcuttur.

Yang ve diğ. (2021), arazi kullanımını hiyerarşik olarak ve aynı anda birden fazla düzeyde tahmin etmeyi amaçlayan ESA tabanlı yeni bir yöntem önermişlerdir. RGB ortofotolardan oluşan iki farklı veri setinden bir veri seti oluşturulmuştur. Çalışmada 3 farklı semantik katman oluşturmuşlardır. Rousset ve diğ. (2021) Tarafından yayınlanan çalışmada karmaşık, tropikal bir ortamda AKAÖ sınıflandırmasını gerçekleştirmek için farklı derin öğrenme yöntemleri karşılaştırılmıştır. Bu amaçla, SPOT6 uydu verilerine dayalı özel bir veri seti oluşturulmuştur. Bu veri seti, Yeni Kaledonya'yı bir insan operatör tarafından etiketlenen beş temsili bölgeden oluşmaktadır: dördü eğitim seti ve beşincisi test seti olarak kullanılmıştır. Derin öğrenme yöntemleri sonucunda elde edilen sınıflandırma sonuçları, güncel bir makine öğrenimi tekniği olan XGboost ile karşılaştırılmıştır. Bu çalışmada önerilen yaklaşıma benzer bir yapıya sahip olduğundan, tez çalışması için bu yayın önemlidir. Tezde sadece yöntem açısından karşılaştırma değil derin öğrenme sonuçlarını iyileştiren bir sonradan işleme (post-processing) yöntemi de sunulmuştur. Henry ve diğ. (2019) tarafından yapılan çalışmada doğal görüntülerin semantik segmentasyonunu gerçekleştirmek için geliştirilmiş derin sinir ağlarını kullanarak uydu görüntülerinden AKAÖ haritalarının oluşturulmasını otomatikleştirmeye yönelik bir yaklaşım önerilmiştir. Önceden ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) veri seti üzerinden eğitilmiş ağırlıkların hassas ayarı için Kanada'daki Manitoba Eyaletinden alınan 224×224 çözünürlüklü yaklaşık 19.000 adet Landsat 5/7 uydu görüntüsü kullanılmıştır. Yine aynı bölgede Alhassan ve diğ. (2020) tarafından yapılan çalışmada Henry ve diğ. (2019) tarafından benzer şekilde multispektral uydu görüntülerinden AKAÖ haritalama için otomatik bir yöntem önerilmiştir. Bu AKAÖ haritalama işlemi, ImageNet büyük ölçekli görsel tanıma yarışması veri setinde önceden eğitilmiş ve Kanada'nın Manitoba Eyaletinden alınan Landsat 5/7 multispektral uydu görüntülerinden oluşan hedef veri setinde ince ayar yapılan derin öğrenme yöntemleri kullanılmıştır. Böylece yarı-otomatik AKAÖ harita üretim tekniklerinin kullanımı yerine daha hızlı otomatik bir yöntem geliştirilmesi amaçlanmıştır. Kullanılan derin öğrenme ağları FCN-VGG16, FCN-GoogleNet ve FCN-ResNet'tir. Ancak bu çalışmada da sınıflandırma derin öğrenme yöntemlerinin performansları ile sınırlıdır. Eğitim aşamasında veya veri setinde oluşabilecek bir

eksiklik yeterli doğrulukta bir sonuç elde edilememesine sebep olabilir. Bu tarz durumlarının önüne geçmek için sınıflandırmayı iyileştirici yöntemlerin kullanılması faydalı olmaktadır. Arazi kullanımı için ESA kullanarak geo-konumsal bir veri tabanı kullanan çalışma Yang ve diğ. (2018) tarafından gerçekleştirilmiştir. Bu çalışmada, arazi kullanım sınıfının büyük çokgenleri, birden fazla parça şeklinde ESA ile sınıflandırılmıştır. Gujrathi ve diğ. (2020), tek seviyeli arazi kullanım sınıflandırması için Yang ve diğ. (2018) yöntemini baz alarak DenseNet (Huang ve diğ, 2017) modulünü entegre etmiştir. Yang ve diğ. (2020b) önceki çalışmalarındaki (Yang ve diğ, 2018) ağ mimarisini modelleyerek çoklu semantik seviyede arazi kullanımı ürettir. Bir başka çalışmada 10 farklı arazi kullanım sınıfını aynı anda sınıflandırmayı Multi Layer Perceptron ve ESA yardımıyla gerçekleştirilmiştir (Zhang ve diğ, 2018).

Hua ve diğ. (2019) ESA tabanlı model ile çoklu-etiket sınıflandırmasını hava fotoğrafları kullanarak gerçekleştirmişlerdir. Bu çalışmada, bir görüntüdeki çoklu etiketler tahmin edilmiştir. Ancak, bu tahminde görüntülerdeki sınıfların birbiriyle olan anlamsal ilişkisi kullanılmamıştır. Bu durumda sınıf hiyerarşisi sonuçlara yansımayacaktır. Farklı seviyeler arası ilişkinin de kullanıldığı çalışma, çoklu-görev öğrenmesidir (multi-task learning) ve bu uygulamaya örnek olarak Leiva-Murillo ve diğ. (2012) bir çalışma gerçekleştirmişlerdir. Deng ve diğ. (2014) çalışmasında, ESA tabanlı çoklu semantik seviyelerin sınıflandırılması amaçlanmıştır. Bu çalışmada Hierarchy and Exclusion (HEX) kullanılmış ve farklı türdeki semantik ilişkiler modellenmiştir. Ancak işlemler oldukça karmaşık yapıda ve zaman alan şekildedir. Yang ve diğ. (2021), çalışmasında, aynı anda arazi örtüsü ve farklı seviyede arazi kullanımı sınıflandırmasını Sayısal arazi modeli (SAM) ve Sayısal yüzey modeli (SYM) katmanlarını da kullanarak ESA tabanlı şekilde üretmişlerdir. Çalışmada, ağ modifikasyonu kullanarak FuseNet-Lite kullanımı mevcuttur. ESA için görüntü girdi boyutu 256 x 256 şeklindedir.

Audebert ve diğ. (2016), ESA mimarisini kullanarak heterojen sensörlerden (optik ve lazer) çoklu çekirdekler ve veri füzyonu kullanarak semantik segmentasyon sınıflandırma doğruluğunu artırabilecek bir yöntem önermiştir. Aynı çalışmada, çoklu çözünürlüklü bölütleme ile görüntü bölütleri üretilmiştir. Her bir segment için NDVI, homojenlik, parlaklık ve dikdörtgen uyum özellikleri, Endonezya'da Semarang'dan alınan görüntüler yardımıyla elde edilmiş ve derin öğrenmeye girdi olarak verilmiştir. Uzaktan algılamada bir başka semantik segmentasyonu uygulaması Kemker ve diğ.

(2018) tarafından yapılmıştır. Çalışmalarında multispektral görüntüler (MSG) kullanılmış ve derin evrişimsel sinir ağları (DESA) kullanılarak sentetik MSG'ye uygulanmıştır. Elde edilen ağırlıklar, piksel bazında sınıflandırma yapmak için çok yüksek çözünürlüklü (ÇYÇ) MSG verilerine aktarılmıştır. Liu ve diğ. (2021) OBIA (NTGA) ve DÖ'yü birleştirmeyi önererek, doğal afetler için değişiklik tespit analizi için ÇYÇ uzaktan algılama görüntüleri ile test yapmışlardır. Başka bir çalışmada (Ghorbanzadeh ve diğ, 2021), Geo Eye-1 ve Worldview-1 görüntüleri ESA mimarisinde kullanılmıştır. Ortaya çıkan ESA olasılıkları, bir mülteci kampındaki konutların örnek (instance) bölümlendirmesini oluşturmak için NTGA bölütlemesi ve bulanık sınıflandırma kullanılarak nesne iyileştirme adımı için kullanılmıştır. Papadomanolaki ve diğ. (2019) geliştirilmiş bir nesne tabanlı öğrenme çerçevesi kullanmış ve sonuçları ÇYÇ görüntülerinde ESA kullanarak piksel tabanlı öğrenme ile karşılaştırmışlardır. Martins ve diğ. (2020) NTGA, nesne analizi için iskelet tabanlı algoritma kullanımı ve yüksek mekânsal çözünürlük kullanarak arazi örtüsü haritalaması için çeşitli ESA ile gerçekleştirilerek önerilen yöntemin genel doğruluğu %87.2 olarak bulunmuştur. Başka bir çalışmada (Liu ve diğ, 2018), insansız hava aracı sistem görüntülerini kullanarak nesne tabanlı sulak alan haritalaması için tamamen evrişimli ağlar, makine öğrenimi algoritmaları ve görüntü-boyutu (patch) tabanlı DESA sonuçlarını karşılaştırılmıştır. Li ve diğ. (2019) yüksek çözünürlüklü görüntülerle AKAÖ haritalaması için nesne tabanlı ESA modelini içeren bir yöntem kullanmıştır. Tuia ve diğ. (2018) semantik segmentasyon için alan bazlı bir analiz olarak bir model önermişler ve mekânsal düzenlemeyi (regularization) kullanmışlardır. Çalışmada, bölge seviyesini (region level) (ilgili piksel grubu) ÇYÇ uydu ve hava görüntülerinde yaptıkları uygulamaya conditional random field (CRF) yöntemini uygulamışlardır. Lv ve diğ. (2015) yılında yayınladıkları çalışmalarında RADARSAT-2 PolSAR verilerini kullanarak 10 farklı arazi örtüsü sınıfının derin öğrenme ile çıkarmışlardır. Kullanılan çok bantlı görüntüler SYM modeli kullanılarak ortorektifiye edilmiştir. Böylece yükseklik farkı sebebiyle oluşan görüntü üzerindeki bozukluklar giderilmiştir. Ardından bu görüntüler Pauli RGB görüntüsüne çevrilmiştir. Derin öğrenme yöntemi olarak kontrolsüz bir yöntem olan Deep Belief Nets (DBN) kullanılmıştır. Paisitkriangkrai ve diğ. (2015) tarafından ESA özelliklerini, elle müdahale özellikleri ve Koşullu Rastgele Alanları (CRF'ler) kullanan bir semantik segmentasyon yöntemi önerilmiştir. Hem ESA hem de el yapımı özellikler, piksel sınıflarını tahmin etmek için her bir sınıf için oluşturulan 7500

görüntü parçasına uygulanmıştır. CRF ise etiketlerin kenarlarının yumuşatılması için kullanılmıştır. Çalışmada ayrıca farklı görüntü parçacığı boyutları (16x16, 32x32 ve 64x64) oluşturularak da inceleme yapılmıştır. Çalışmada ISPRS Vaihingen veri seti kullanılmıştır. Volpi ve Tuia (2016) tarafından yapılan diğer bir çalışmada ise alt örnekleme sonra yukarı örnekleme kullanımı olan bir mimariye dayanan ESA tabanlı bir AKAÖ sınıflandırma sistemi önerilmiştir. Sistemin temel mantığı ilk önce evrişimler aracılığıyla üst düzey temsillerin kaba bir mekânsal haritasının öğrenilmesi ve ardından bunların ters evrişimlerle orijinal çözünürlüğe geri örneklemesidir. Böylece her doğruluğun ve zaman açısından verimliliğin artırılması amaçlanmaktadır. Girdi verisi olarak ISPRS Vaihingen ve Potsdam veri setlerinden seçilen rastgele görüntü örnekleri kullanılmıştır. Kampffmeyer ve diğ. (2016) tarafından yapılan çalışmada ise kentsel alanlara odaklanarak, uzaktan algılama görüntülerinde arazi örtüsü haritalaması için derin bir ESA geliştirilmiştir. Bu çalışmanın en önemli katkısı arazi örtüsü sınıflandırmalarında göz ardı edilen ve sınıf dengesizliği nedeniyle sınıflandırma doğruluğunu olumsuz etkileyen küçük nesnelere odaklanmasıdır. Önerilen yöntem ile küçük nesneler için hala iyi bir doğruluk elde ederken yüksek genel doğruluk elde edilmesi amaçlanmaktadır. Çalışmada görüntü parçacığı-tabanlı, piksel-tabanlı ve bunların kombinasyonu olarak farklı derin öğrenme mimarileri karşılaştırılmıştır. Veri seti olarak ISPRS Vaihingen veri seti kullanılmıştır. Marmanis ve diğ. (2016) tarafından yayınlanan çalışmada çok yüksek çözünürlüklü görüntülerin semantik segmentasyonuna yönelik bir derin öğrenme yaklaşımını açıklanmıştır. Çalışmada FCN yaklaşımı benimsenmiştir. Piksel tabanlı sınıflandırmada ESA modellerinin farklı piksel katkılarını göz ardı etmesinden dolayı yoğunluk ve aralık bilgisini girdi olarak erken ağ katmanlarının geri dönüşümü yardımıyla bunları tam çözünürlükte piksel bazında sınıflandırmaya dönüştüren bir FCN kullanılmıştır. Çalışma ISPRS Vaihingen veri seti üzerinde gerçekleştirilmiştir. Bina çıkarımı için Marcu ve Leordeanu (2016) tarafından yapılan çalışmada girdi verisini biri yerel diğeri küresel olmak üzere iki bağımsız yol boyunca işleyen çift akışlı bir derin sinir ağı modeli önerilmektedir. İkisi daha sonra işlemenin son katmanlarında birleştirilir. Model, birlikte güçlü bir sınıflandırıcı oluşturacak şekilde, yerel nesne görünümünün yanı sıra daha büyük sahneden gelen bilgileri aynı anda ve tamamlayıcı bir şekilde birleştirmeyi sağlamaktadır. Çalışmada Massachusetts Buildings veri setinin yanı sıra bina ve yol sınıflarını içeren iki yeni veri seti kullanılmıştır.

Diğer bir çalışmada (Zhao ve diğ., 2017) ise komşu pikseller arasındaki semantik benzerlikleri göz önünde bulundurarak segmentler oluşturan için semantik segmentasyon yaklaşımı geliştirilmiştir. Görüntüden elde edilen düşük seviyeli özneliklerin aksine, bu çalışmada, hiyerarşik öğrenme çerçevesi ile yüksek seviyelerde öznelik temsillerini çıkarmak için bir ESA modeli uygulanmıştır. Semantik segmentler ilk önce ESA ile araştırılmış ve daha sonra anlamsal segmentler arasındaki bağlamsal bilgiyi modellemek için bir CRF modeli kullanılmıştır. Böylece semantik segmentasyon için mekânsal şekiller ve semantik içerikler açısından coğrafi varlıkları iyi bir şekilde temsil eden semantik segmentlerin kullanılması sağlanmıştır. Çalışmada ISPRS Vaihingen ve Pekin veri setleri kullanılmıştır. Wang ve diğ. (2017) tarafından yapılan çalışmada ise semantik segmentasyonda farklı katmanlı özellik haritalarını birleştirirken uyarlanabilir özellikleri otomatik olarak seçmek için kullanılabilecek ESA temelli bir yöntem önerilmiştir. Bu yöntem özellik haritalarının bilgi entropisi ile etiket-hata haritası arasındaki ilişkiyi araştıran ve ardından özellik haritalarını daha etkin bir şekilde entegre edilmesini sağlayan bir mekanizmaya sahiptir. Bu mekanizma farklı özellik haritalarına göreli önemlerine göre uyarlanabilir ağırlıklar atamak için oluşturulan entropi haritaları tarafından uygulanır. Seçilen özellikler sonunda, her pikselin anlamsal etiketini tahmin eden sınıflandırıcı katmanını beslemek için birleştirilir. Çalışmada ISPRS Vaihingen veri seti kullanılmıştır. Audebert ve diğ. (2018) tarafından yayınlanan bir başka çalışmada semantik etiketleme için çok modlu ve çok ölçekli uzaktan algılama verilerinin ESA modellerine uyarlanması incelenmiştir. Bu çalışmada LiDAR verisinden elde edilen sayısal yükseklik modelleri ile çok bantlı görüntülerden elde edilen NDVI bantı entegre edilerek üç bantlı yeni görüntüler oluşturulmuştur. Semantik segmentasyon için SegNet-RC, V-FuseNet, ResNet-34-RC ve FusResNet yöntemleri kullanılmıştır. Bu yöntemler veri seti olarak ISPRS Vaihingen ve Potsdam üzerinden uygulanmıştır. Liu cd. (2018) tarafından yapılan çalışmada ise çok yüksek çözünürlüklü görüntülerde karmaşık nesneleri daha doğru sınıflandırmak için ESA temelli ScasNet yöntemi önerilmiştir. Nesneler için ScasNet, kaba-ince iyileştirme stratejisiyle etiketleme doğruluğunu artırır. ESA'nın sığ katmanları tarafından öğrenilen düşük seviyeli özellikleri kullanarak hedef nesneleri aşamalı olarak iyileştirir. Veri seti olarak ISPRS Vaihingen ve Potsdam veri setleri ile beraber Massachussets Building veri seti kullanılmıştır. Panboonyuen ve diğ. (2019) tarafından yapılan çalışmada uzaktan algılama verilerinin semantik segmentasyonu için yeni bir ESA önerilmiştir. Temelde

3 temel katkıda bulunulmuştur. İlk olarak, ağın farklı aşamalarından çok ölçekli özellikleri çıkararak farklı çözünürlükler yakalayabildiğinden, yeni bir ESA'nın uygulanmasını önermektedir. Ayrıca orta çözünürlüklü uzaktan algılanan görüntüler için daha fazla sayıda katman kullanarak ESA omurgası geliştirilmiştir. İkincisi, en ayırt edici özellikleri seçmek için ağda “kanal dikkati” olarak adlandırılan bir yaklaşım sunulmaktadır. Üçüncüsü, farklı çözünürlüklere sahip diğer uzaktan algılanmış veriler üzerinde önceden eğitilmiş modeller kullanılarak “alana-özü transfer öğrenme” açıklanmıştır. Daha sonra verilen iki veri seti üzerinde uygulama gerçekleştirilmiştir: (i) Landsat-8 uydusundan toplanan orta çözünürlüklü veriler ve (ii) ISPRS Vaihingen veri seti olarak adlandırılan çok yüksek çözünürlüklü veriler. Li ve diğ. (2019) tarafından yayınlanan çalışmada DeepGlobe Satellite Challenge of IEEE Conference on Computer Vision and Pattern Recognition 2018'de sağlanan SpaceNet bina veri setini kullanarak yüksek çözünürlüklü çok-bantlı uydu görüntülerinden bina ayak izlerinin çıkarılması için U-Net tabanlı bir semantik segmentasyon yöntemi önerilmiştir. U-Net tabanlı semantik segmentasyon modeliyle, veri artırma, işleme ve CBS harita verilerinin ve uydu görüntülerinin entegrasyonu dahil olmak üzere çeşitli stratejiler tasarlanmıştır. Dört şehirde (Las Vegas, Paris, Şanghay ve Hartum) WorldView-3 uydu veri kümeleri ile CBS harita veri kümesinin (OpenStreetMap, Google Haritalar ve MapWorld) entegrasyonu araştırılmıştır. Chen ve diğ. (2019) tarafından yapılan çalışmada yüksek çözünürlüklü uydu görüntülerinin semantik segmentasyonu işleminde görüntü verilerinin özelliklerinden kaynaklanan küçük nesnelerin düşük doğrulukla sınıflandırılması ve belirsiz sınırlar sorunlarının çözümü için önceden eğitilmiş kodlayıcıyı benimseyen gelişmiş bir anlamsal bölümlendirme sinir ağı önerilmiştir. Söz konusu ağ bu tezde de kullanılan DeepLabv3 mimarisine dayalı olarak geliştirilmiştir. Geliştirilmiş sinir ağı mimarisi, küçük nesnelerin tanınmasının kesinliğini iyileştirmektedir. Pan ve diğ. (2020) tarafından yapılan çalışmada U-net mimarisine dayalı bir kentsel köy haritalama paradigması önerilmiştir. Bu yaklaşımda karmaşık bir kentsel köydeki bireysel binaları karakterize etmesi amaçlanmıştır. Çalışma alanı olarak Çin'in Guangzhou şehrinde seçilmiştir. 0,5 m uzamsal çözünürlükte sekiz bantlı Worldview uydu görüntüsü ve bina sınır vektör dosyası kullanılmıştır. Bu çalışma ile derin öğrenme yöntemleri aracılığıyla, plansız kentsel yerleşimlerin haritalanmasının mümkün olduğu gösterilmiştir. Zhang ve Chi (2020) tarafından yapılan çalışmada ise küçük nesnelerin yanlış sınıflandırılması problemine çözüm aranmıştır. Bu bağlamda tamamlayıcı bir bileşen olarak nesne tespiti için

olduka etkili olan, blgelere sahip bir evriřimli derin ađ (R-CNN) kullanılmaktadır. nerilen ađ, Mask R-FCN olarak adlandırılmaktadır. Hem anlamsal bir modelden gelen anlamsal haritaları hem de nesne algılama modelini birleřtirmek iin đrenme tabanlı bir yaklařım sunulmuřtur. Veri seti olarak Zurich Summer veri seti, Gaofen Image Dataset ve DataFountain2017 kullanılmıřtır.






2. MATERYAL VE YÖNTEM

2.1 Uygulamada Kullanılan Veri Setleri


Çalışma kapsamında üç farklı veri seti üzerinde uygulama yapılmıştır. İlk iki uygulama ve sonuçları kullanılarak tezden üretilmiş bir yayın hazırlanmıştır (Atik ve İpbüker, 2021a). Sentinel-2 ve Zurich summer veri setindeki uygulama ve sonuçları 2021 yılında basılan “Integrating Convolutional Neural Network and Multiresolution Segmentation for Land Cover and Land Use Mapping Using Satellite Imagery” isimli yayın doğrultusunda hazırlanmıştır.

2.1.1 Sentinel-2 veri seti


Çalışma alanı İstanbul'un Avrupa ve Asya yakasında, Muğla'da Marmaris bölgesinde ve Kocaeli'de Gölcük bölgesinde yer alan yaklaşık 658 km²'lik bir alandır (Şekil 2.1). Çalışma alanı olarak, üç farklı şehirden, yerleşim alanları, su yapıları ile orman ve yarı doğal alanları yaklaşık eşit ağırlıkta içeren bölgeler seçilmiştir. Bu şehirler ülkenin kuzeybatı ve güneyinde yer almakta olup, iklim, demografik yoğunluk ve arazi kullanım farklılıkları nedeniyle farklı kentsel ve orman doku özelliklerine sahiptirler. Bu alanlar, ulusal AKAÖ ürünlerinde olduğu gibi, mümkün olduğunca geniş bir alana uygulanabilecek uygun ve uyarlanabilir bir yöntemin geliştirilmesine olanak sağlamak için seçilmiştir. Bu bölgelerde eğitim, test ve doğrulama (validasyon) görüntüleri ayrı ayrı seçilmiştir. Uygulamada kullanılan modellerin testi için İstanbul'da bir alan (Şekil 2.2) ve Kocaeli şehrinde bir alan (Şekil 2.3) seçilmiştir. Eğitim için İstanbul'da üç farklı alan (Şekil 2.2) ve Muğla'dan bir alan (Şekil 2.4) seçilirken, doğrulama için İstanbul'dan bir alan seçilmiştir.




Şekil 2.1 : Türkiye'de çalışma alanı için seçilen illerin dağılımı.



Şekil 2.2 : İstanbul şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri.



Şekil 2.3 : Kocaeli şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri.



Şekil 2.4 : Muğla şehrinde yapılan çalışma için seçilen Sentinel-2A görüntüleri.

Uydu görüntüsü olarak, uygulamada giriş Sentinel-2A görüntüsü kullanılmıştır. Sentinel-2 verileri Sentinel-Hub'dan (URL-3) ve URL-4'ten ücretsiz olarak elde edilmektedir. Sentinel-2A ürünleri, UTM/WGS84 projeksiyonunda ortalama görüntülerdir. Bu çalışmada kullanılan tüm uydu görüntüleri için verinin algılanma tarihi 24 Mayıs 2020'dir. 10 m uzaysal çözünürlükte deney verilerinin hazırlanması için kırmızı, yeşil, mavi ve yakın kızılötesi (NIR) bantlar seçilmiştir. Copernicus Programından bir Dünya gözlem görevi olan Sentinel-2'den alınan görüntüler, aşağıdaki nedenlerle bu uygulamada girdi verisi olarak kullanılmıştır: (i) uydunun kapsama alanı geniş olması (290 km'lik bir alan genişliği) (ii) 2015 ve 2017'de başlatılan bir Avrupa Uzay Ajansı (ESA) görevidir. 443-2190 nm ile 13 bantlı multispektral görüntüler olan ticari olmayan ve ücretsiz veriler sağlarlar ve AKAÖ sınıflandırmak için bantlar aracılığıyla birçok spektral indeksin üretilmesine izin verirler. Sentinel görüntüleri, konumsal, spektral ve yüksek zamansal çözünürlük açısından bölgesel izleme programları için oldukça uygundur (tek bir Sentinel-2 uydusu için bu süre 10 gündür ve aynı bölgeyi tekrar ziyaret sıklığı 5 gündür). Derin

öğrenmede, ÇYÇ görüntüleri ile tematik haritalar üretmek, pahalı GPU birimleri ve bilgisayar sistemi gereksinimleri gerektirir. Oysa Sentinel görüntülerini bu modellerde işlenmesi işlem yükü olarak ÇYÇ görüntüler kadar güç olmayacaktır. Bu ve bu gibi nedenlerden dolayı Sentinel-2 görüntüleri, tematik harita oluşturma gereksinimleri için uygundur (Atik ve İpbüker, 2021a). Çizelge 2.1’de Sentinel uydusunun özellikleri gösterilmiştir.

Çizelge 2.1 : Sentinel 2A uydusunun özellikleri (URL-5).

Özellik	Değer
Spektral Bant Sayısı	13
Spektral Çözünürlük	433-2280 nm
Mekânsal Çözünürlük	Bant 2, Bant 3, Bant 4, Bant 8 (10 m) Bant 5, Bant 6, Bant 7, Bant 8A, Bant 11, Bant 12 (20 m) Bant 1, Bant 9, Bant 10 (60 m)
Radyometrik Çözünürlük	12 bit
Zamansal Çözünürlük	5 gün

Sentinel-2 uygulaması, arazi örtüsü sınıflandırma sistemlerinin (LCCS) birinci seviyesinin üç sınıfını içermektedir. Yapay yüzeyler sınıfı, kentsel doku, endüstriyel birimler, çöplükler, inşaat, maden sahaları ve yapay olarak bitkilendirilmiş tarım dışı alanları içerir. Orman ve yarı doğal alanlar sınıfı; ormanlar, maki ve otsu bitki toplulukları ile bitki örtüsünün az olduğu veya hiç olmadığı açık alanlardan oluşmaktadır. Su yapıları, iç suları ve deniz sularını içerir. Tüm bu sınıflar, tüm eğitim ve test alanlarında bulunmaktadır. Çizelge 2.2’de sınıfların istatistik bilgileri paylaşılmıştır. Bu veri seti çalışma kapsamı için oluşturulmuş olup, bu kapsamda üretilmiş makalede de kullanılmıştır (Atik ve İpbüker, 2021a). Bu veri seti dengeli (balanced) veri seti niteliğindedir.

Çizelge 2.2 : Sentinel veri setinde sınıf dağılımları.


Sınıf	Piksel Sayısı	Yüzde (%)
Yapay yüzeyler	1 972 691	30.0
Orman ve yarı-doğal alanlar	2 266 083	34.5
Su yapıları	2 331 916	35.5

Sınıflandırma süreci, yaygın olarak kullanılan birinci seviye LCCS sınıflarını takip eder. Örneğin, CLC terminolojisinde, birinci seviye tematik haritalar 1:100.000’e karşılık gelir ve minimum kartografik birime (minimum mapping unit - MMU) 25 ha ve geometrik doğruluğu 100 m’den daha iyidir (URL-2). Bu seviyedeki sınıfları içeren


arazi örtüsü harita üretiminde haritalarda kullanılan ölçek nedeniyle, çalışmada kullanılacak veri setindeki referans görüntüleri kartografik genelleştirme yardımı ile üretilmiştir (Atik ve İpbüker, 2021a).

2.1.2 Zurich Summer Veri Seti

Zurich Summer v1.0 veri seti (Volpi ve Ferrari, 2015) pan-keskinleştirilmiş 0,61 m mekânsal çözünürlüğe sahip 20 kesilmiş QuickBird uydu görüntüsü içerir. Görüntüler dört kanala (NIR, R, G ve B bantlarına) sahiptir ve sekiz farklı kentsel ve kent çevresi sınıfı içerir. Sınıflar yollar, binalar, ağaçlar, çimenler, çıplak toprak, su, demiryolları ve yüzme havuzlarıdır. Şekil 2.5’de örnek görüntü gösterilmektedir. Veri kümesi sınıf dağılımı, gerçek dünyaya benzer şekilde dengesizdir (imbalanced). Görüntüler yaklaşık 23 milyon piksele sahiptir. Deneyde, test görüntüleri olarak ZH-16 ve ZH-17 görüntüleri ve doğrulama verileri olarak ZH-20 görüntüleri kullanılmıştır; diğer görsellerin tamamı modellerin eğitiminde kullanılmıştır. Veri seti dengesiz bir veri seti olduğu için, sınıf ağırlıklarında olan önemli fark mevcuttur. Bu fark grafiksel olarak gösterilmektedir (Şekil 2.6). Aynı zamanda sayısal olarak, sınıflara ait ağırlık bilgileri de mevcuttur (Çizelge 2.3).



Şekil 2.5 : Zurich Summer veri setinden (ZH-12) örnek görüntü.



Şekil 2.6 : Zurich Summer veri seti sınıflarının yoğunluk gösterimi.

Çizelge 2.3 : Zurich Summer veri seti sınıf dağılımı.

Sınıf	Piksel Sayısı	Yüzde (%)
Yol	3 227 800	24.6
Bina	4 793 600	36.5
Ağaç	2 161 300	16.5
Çim	1 406 800	10.7
Boş Arazi	175 520	1.34
Su	1 006 400	7.67
Demiryolu	323 270	2.46
Yüzme Havuzu	27 473	0.21

2.1.3 Wuhan University Building Extraction Dataset (WHUBED) Veri Seti

Çalışmada, uydu görüntülerinde binaların çıkarılması için Wuhan Üniversitesi Bina Veri Kümesi – Wuhan University Building Extraction Dataset (WHUBED) kullanılmıştır. Veri seti yedi ilden (Doğu, Kuzeybatı, Güney ve Orta Çin bölgeleri) gelen 31 pan-keskinleştirilmiş görüntü içermektedir. Bu görüntüler algılanan görüntüler ÇYÇ görüntülerdir (Bi ve diğ, 2019). Görüntüler toplamda 57 adettir ve boyut olarak 512×512 pikseldir. Ek olarak, her görüntü için, bina ve bina dışı sınıflara ait referans verisi (GT) sahiptir. Veri seti iki farklı bant kombinasyonunu (NIR, R ve

G bantlar; R, G, B bantlar), GT görüntüsü, ROI ve xml dosyalarını içerir. Veri setinde, bina ve bina olmayan şeklinde iki sınıf mevcuttur. Şekil 2.7’de veri setine ait seçilen bazı örnek görüntüler gösterilmiştir. Çalışma kapsamındaki uygulamada NIR, R, G bant kombinasyonu kullanılmıştır. Veri setinde bina sınıfının dağılımı gösterilmiştir (Çizelge 2.4).

Çizelge 2.4 : WHUBED veri seti sınıf istatistikleri.

Sınıf	Piksel sayısı	Sınıf Ağırlıkları
Bina	2 UR120 504	0.162
Bina olmayan	10 986 696	0.838



Şekil 2.7 : WHUBED veri setine ait bazı görüntüler (Bi ve diğ, 2019).

2.2 Evrişimsel Sinir Ağları (ESA)


Verilerden öğrenebilen özellik eklendiğinde kural tabanlı sistemler klasik makine öğrenmesi gibi çalışabilir. Veriden öğrenme özelliği ile daha fazla katman eklenerek temsili öğrenme uygulanabilir. Temsil öğrenimi, yapay zekanın daha az insan müdahalesi ile yeni görevlere hızla uyum sağlamasına olanak tanır (Goodfellow ve diğ, 2016). Bilgisayarla görü görevleri için özel mimariler, evrişimli ağlar olarak adlandırılır. ESA’lar, giriş verisi özelliklerini anlamaktan sorumlu olan birçok evrişimsel katman içerir. Evrişim katmanları, görüntüdeki düşük ve yüksek seviyeli

özellikleri çıkarmak için görüntüye filtreler uygular. Öne çıkan bir görüntü elde edilir ve bu, ilk filtreyi uygulayarak bir özellik tipini tanımlar. Ardından, ikinci bir özellik görüntüsü, başka bir özellik türünü algılayan ikinci bir filtre kullanır (Atik ve İpbüker, 2021a). Ek olarak, çoğu makine öğrenimi algoritması, algoritmanın davranışını kontrol etmeye yardımcı olan hiperparametreler adı verilen ayarları içerir (Goodfellow ve diğ., 2016). Modeller kurulurken ve kullanılırken modele fazla uyum (overfitting) veya eksik uyum (under-fitting) istenmeyen durumlardır. Evrişimli bir ağ ile kullanılan veriler genellikle birden çok kanaldan oluşur. Sentinel-2 ve Zurich Summer veri seti uygulamalarında girdi veriler, farklı görüntü bantları olarak üçten fazla kanala sahiptir.

Sinir ağları ile ilgili dikkate alınması gereken bir diğer kritik nokta, kullanılacak mimariye karar vermektir (Goodfellow ve diğ., 2016). Farklı kombinasyonlarla (evrişim – konvülasyon katmanı, havuzlama, ReLU (Rectified Linear Unit) aktivasyonu vb.) birçok farklı ESA modeli oluşturulmuştur. Çalışma kapsamında ESA modelleri gibi farklı mimariler kullanılarak deneyler yapılmıştır. Bazı yeni çalışmalar, optimum ESA mimarisine sahip veri kümeleri için otomatik bir çerçeve bulmaya çalışırken, diğer görevlere (konut tespiti gibi) aktarılabilirlik belirgin değildir (Ghorbanzadeh ve diğ., 2021). Bu nedenle, optimum ESA modelinin belirlenmesi ve evrişimin hiper parametreleri vaka çalışmalarına göre değişebilir.

2.2.1 U-Net mimarisi

23 evrişim katmanına sahip U-Net (Ronneberger ve diğ., 2015) mimarisi, çok kanallı özellik haritaları içerir. Her birinin ardından bir ReLU işlemi ve 2×2 maks-havuzlama kısmı ile iki 3×3 evrişimin tekrarı vardır. U-Net mimarisindeki önemli değişiklik, örnekleme bölümünde birçok özellik kanalına sahip olmanın, ağın bağlam bilgilerini daha yüksek çözünürlüklü katmanlara yaymasını sağlamasıdır. Sonuç olarak, geniş yol (expansive path), darboğaza (bottleneck) simetrik ve U şeklinde bir mimari oluşturur. Bu mimari, çeşitli biyomedikal görüntülerin segmentasyon uygulamalarında iyi performans sağlamıştır (Ronneberger ve diğ., 2015). Çok az eğitim verisi ile çalışması ve yine de prezisyonlu segmentasyon sonuçları vermesi nedeniyle birçok bilgisayarlı görü segmentasyon görevi için geniş bir kullanıma sahiptir (Atik ve İpbüker, 2021a). Çalışmada kullanılan U-Net mimarisi çizimi Şekil 2.8'de gösterilmektedir.



Şekil 2.8 : Çalışmada kullanılan U-Net mimarisinin gösterimi.


U-Net modelinin genel çerçevesi, 3×3 pencere boyutunda bir evrişim katmanından ve ardından 2×2 pencere boyutunda bir altörnekleme katmanı serisinden oluşur. Evrişim işlemi sırasında, bir dönüşüm fonksiyonu olan aktivasyon fonksiyonu (Eşitlik (2.1)) kullanılır.

$$Z(x_k(ii, jj)) = f(\sum_{k=1}^k x_k(ii, jj) \cdot w_k + b_k) \Leftrightarrow Z = f(x \cdot w + b) \quad (2.1)$$

burada w ağırlık vektörünü ifade eder, b ön gerilim vektörüdür ve $x_k(ii, jj)$ aktivasyon fonksiyonunun girdisi ve evrişim işleminin çıktısıdır (Abdollahi ve diğ., 2020).

2.2.2 SegNet mimarisi

SegNet (Badrinarayanan ve diğ., 2017), giriş görüntüsüyle aynı boyutta piksel bazında sınıflandırma için tahmin çıktısı veren tamamen evrişimli bir sinir ağı mimarisidir. Ağ, kodlayıcı-kod çözücü katmanlarını, evrişim katmanlarını, toplu normalleştirmeyi, havuzlama endekslerini ve ReLU aktivasyon aşamalarını içerir. Altörnekleme ve üstörnekleme bölümlerinin yapısında simetri vardır. Son olarak ESA ağı, softmax katmanı ile segmentasyon sonucunu üretir. Bu mimari Şekil 2.9'da gösterilmektedir.



Şekil 2.9 : Çalışmada kullanılan SegNet mimarisinin gösterimi.


Her kodlayıcı ve kod çözücü ağı, özellik haritalarını oluşturmak ve toplu olarak normalleştirmek için bir filtre bankası oluşturur. Bundan sonra, ReLU katmanı bir etkinleştirme işlevi uygular. ReLU katmanını, 2×2 çekirdek boyutuna sahip bir maksimum havuzlama katmanı izler. Son kod çözücü ağında, görüntüdeki her pikseli sınıflandırmak için olanak oluşturmak için softmax (Eşitlik (2.2)) adlı çok sınıflı bir sınıflandırıcı kullanılır (Badrinarayanan ve diğ, 2017).

$$s(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2.2)$$

burada n sınıf sayısını ifade eder, x modelin çıktı vektörüdür ve i indeksi 0 ila $n-1$ aralığındadır. Bu çalışmada, başlangıç ağırlıkları olarak VGG-16 (Simonyan ve Zisserman, 2014) modelinin ağırlıkları kullanılmıştır.

2.2.3 DeepLabV3+ mimarisi

Derin Evrişimsel Sinir Ağları semantik segmentasyon görevi için yaygın şekilde kullanılmaktadır. DESA'ların ardı ardına gelen havuz ve evrişim katmanları segmentasyon görevleri için görüntülerde girdi özelliği taşıyan haritalarının gittikçe küçülmesidir. Bu durum görüntülerde bilgi kaybına neden olur. Tahminlerin düşük mekansal çözünürlüklü ve nesne sınırlarının bulanık olduğu çıktılarla sonuçlanır. DeepLab modeli, Atrous evrişimleri ve Atrous Spatial Pyramid Pooling (ASPP) modüllerini kullanarak bu problemi çözmeyi amaçlamaktadır (Chen ve diğ, 2017a). DeepLabv3 toplu normalleştirme ve görüntü düzeyi özellikleri dahil ederek geliştirilmiş bir ASPP modülü kullanır. Önceki versiyonlardaki özellik görünütüsü boyutunu ayarlamak için kullandığı koşullu rastgele alan uygulamasını devre dışı bırakır.



Şekil 2.10 : DeepLab mimarisinin genel gösterimi (Chen ve diğ, 2018).

Atrous evrişimleri evrişimli ağlarda özelliklerin ne kadar yoğun bir şekilde hesaplanacağını kontrol edilmesini sağlamaktadır. Diğer bir deyişle evrişimin görüş alanının boyutunu kontrol edilebilmektedir. Bunun için “atrous oranı” veya “dilatasyon oranı” denilen bir parametre kullanılmaktadır.

İki boyutlu sinyalleri dikkate alırsak, y çıkışındaki her i konumu ve bir w filtresi için, giriş özellik haritası üzerine atrous evrişimi uygulanır (Eşitlik 2.3).

$$y[i] = \sum_k x[i + r \cdot k]w[k] \quad (2.3)$$

Burada r , atrous oranını ifade etmektedir. Atrous evrişimi filtrenin her uzamsal boyut boyunca iki ardışık filtre değeri arasına $r-1$ adet sıfır eklenerek üst örnekleme sağlanmaktadır. Standart evrişimlerde $r=1$ değerini almaktadır (Chen ve diğ, 2017b). Atrous konvolüsyonu, hız değerini değiştirerek filtrenin görüş alanını uyarlamalı olarak değiştirmeye izin vermektedir.

Sonuç olarak, özellik haritalarının boyutunu küçültmeden, çok ölçekli nesneler için tam evrişimli ağlardaki özellikleri hesaplanabilir. Bu, standart derin evrişimli ağlarda kademeli evrişim veya havuzlama işlemi uygulanarak yapılır. Atrous evrişimleri

parametre sayısını etkilemeden filtrelerin görüş alanını büyütmek için basit ama güçlü bir tekniktir.

ASPP, çok ölçekli bağlam bilgisi elde etmek için kullanılır. ASPP ağında, omurgadan çıkarılan öznitelik haritasının üstünde nesneyi farklı ölçeklerde segmentasyonu işlemek için farklı atrous oranlarına sahip dört paralel atrous evrişimi uygulanır. İsteğe bağlı bir ölçeğin bölgelerini doğru ve verimli bir şekilde sınıflandırmak için özelliği farklı ölçeklerde yeniden örneklemek etkilidir. Omurganın son özellik haritasına global ortalama havuzlama uygulanarak global bağlam bilgilerini dahil etmek için görüntü düzeyindeki özellikler de uygulanır. Tüm işlemler paralel olarak uygulandıktan sonra, kanal boyunca her işlemin sonuçları birleştirilir. ASPP ağından gelen çıktı, görüntü için son segmentasyonda maske olacak görüntünün gerçek boyutunu elde etmek için 1 x 1 evrişimden geçirilir (Chen ve diğ, 2017a).

DeepLab modeli özellik çıkarımı aşamasında farklı mimariler ile birlikte kullanılabilir. Bu çalışmada DeepLabv3+ modeli içerisinde ResNet-18, ResNet50, Mobilenetv2 ve Xception mimarileri kullanılmıştır.


2.2.4 ResNet

AlexNet'ten günümüze ESA mimarileri daha da derinleşmiştir. Ancak derin mimariler yalnızca katmanların bir araya gelmesiyle başarılı olmamaktadır. Daha derin bir modele daha fazla katman eklemek, daha yüksek eğitim hatalarına yol açabilmektedir (Atik ve Duran, 2020). Daha derin ağlar yakınsamaya başladığında, bir bozulma sorunu ortaya çıkar. Sinir ağının katman sayısı arttıkça doğruluk seviyeleri doygun hale gelebilir ve bir noktadan sonra yavaş yavaş düşebilir. Sonuç olarak, modelin performansı hem eğitim hem de test verileri üzerinde bozulmaktadır. Bozulma (eğitim doğruluğunun), tüm sistemlerin optimize edilmesinin benzer şekilde kolay olmadığını gösterir (He ve diğ, 2015).

ResNet, tam da bu sorunun üstesinden gelmek amacıyla oluşturulmuştur. ResNet (He ve diğ, 2015), mimarisinde ağ optimizasyonunu kolaylaştırmak ve önemli ölçüde artırılmış derinlik ile doğruluğu artırmak için ESA mimarisine birkaç yığılmış artık (residual) birim eklenmiştir. Artık blokların merkezinde yer alan "bağlantıları atlama" kavramı bu tarz sinir ağlarının temelini oluşturmaktadır. Bu atlama bağlantıları iki şekilde çalışır. İlk olarak, gradyanın geçmesi için alternatif bir kısayol ayarlayarak kaybolan gradyan sorununu hafifletirler. Ayrıca, modelin bir kimlik fonksiyonunu

öğrenmesini sağlarlar. Böylece modelin üst katmanlarının alt katmanlardan daha kötü performans göstermemesi sağlanır.

Ağın girişten çıkışa kadar olan kısmı, doğrusal olmayan bir $H(x)$ işleviyle tanımlanabilir. ResNet mimarisinde bu yol, $F(x) = H(x) - x$ olarak tanımlanan doğrusal olmayan başka bir fonksiyonla eşlenir. Ayrıca girişten çıkışa kısayol bağlantısı yapılarak x (giriş) değeri $F(x)$ fonksiyonuna aritmetik olarak eklenir. $F(x) + x$ fonksiyonu birlikte ReLU katmanından geçirilir (Şekil 2.11). Önceki katman verilerinin sonraki katmanlara etkin bir şekilde aktarılması amaçlanır.



Şekil 2.11 : Artık öğrenmenin temel gösterimi (He ve diğ, 2015).

Sonuç olarak ResNet, hata yüzdesini en aza indirirken daha fazla sinir katmanıyla derin sinir ağlarının verimliliğini artırır. Başka bir deyişle, atlama bağlantıları, önceki katmanlardan gelen çıktıları yığın katmanların çıktılarına ekleyerek, daha önce mümkün olandan çok daha derin ağırları eğitmeyi mümkün kılar. ResNet, yüzlerce hatta binlerce katmana eğitim sağlar ve yine de başarılı bir şekilde çalışır.

İlk ResNet mimarisi, düz bir ağı artık ağ karşılığına dönüştürmek için kısayol bağlantılarının eklenmesini içeren Resnet-34'dir (He ve diğ, 2015). ResNet-34 mimarisi, 3×3 filtrelerle sahip evrişimli ağırlarla VGG sinir ağlarından esinlenmiştir. Ancak, VGG ağırlarıyla karşılaştırıldığında ResNet'ler daha az filtreye ve daha düşük karmaşıklığa sahiptir. Evrişimli katmanlar çoğunlukla 3×3 filtreye sahiptir ve iki basit tasarım kuralı izler: (i) aynı çıktı özelliği eşleme boyutu için katmanlar aynı sayıda filtreye sahiptir; ve (ii) özellik eşleme boyutu yarıya indirilirse, katman başına zaman karmaşıklığını korumak için filtre sayısı iki katına çıkar. Bu mimaride ağırlık katmanı sayısı değiştiğinde ResNet isimlendirmesi de değişir. 18 ağırlık katmanına sahip mimariye ResNet-18 adı verilmiştir (He ve diğ, 2015).

ResNet-50 mimarisi yukarıdaki modele dayalı olsa da, önemli bir fark vardır. Bu durumda, katmanları eğitmek için geçen zamanla ilgili endişeler nedeniyle yapı bloğu bir darboğaz tasarımına dönüştürülmüştür. Burada, önceki 2 yerine 3 katmandan oluşan bir yığın kullanılmıştır. Bu nedenle, Resnet-34'teki 2 katmanlı blokların her biri, Resnet50 mimarisini oluşturan 3 katmanlı bir darboğaz bloğu ile değiştirilmiştir (Şekil 2.12). Bu, 34 katmanlı ResNet modelinden çok daha yüksek doğruluğa sahiptir (He ve diğ, 2015).

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 2.12 : ResNet mimarileri (He ve diğ, 2015).

2.2.5 Mobilenetv2

Yarı-iletken ve transistörlerdeki hızlı gelişmeler derin öğrenmenin her alanda yaygın şekilde kullanılmasının yolunu açmıştır. Böylece büyük verilerin hızlı ve az maliyetli şekilde işlenmesi mümkün olmuştur. Derin öğrenmenin her alanda yaygınlaşması ile yüksek doğruluklu modeller geliştirme ihtiyacı doğmuştur (Baydilli, 2021). Genel eğilim, daha yüksek doğruluk elde etmek için daha derin ve daha karmaşık ağlar yapmak olmuştur. Ancak doğruluğu artırmaya yönelik bu ilerlemeler, ağları boyut ve hız açısından mutlaka daha verimli hale getirmemektedir. Robotik, otonom araç ve artırılmış gerçeklik gibi birçok gerçek dünya uygulamasında hesaplamaların sınırlı bir platformda zamanında gerçekleştirilmesi gerekir. Bu nedenle araştırmalar daha az parametre ile daha verimli derin öğrenme mimarilerinin geliştirilmesi yönünde artırmıştır. MobileNet (Howard ve diğ, 2017) tam olarak böyle bir ihtiyaca cevap vermek için ortaya konmuş bir mimaridir. Basit ve herhangi bir özel operatör gerektirmemekle beraber daha derin ağların doğruluk performansına ulaşabilmektedir. Böylece çoklu görüntü sınıflandırma ve algılama görevlerinde başarılı, daha düşük veri işleme yeteneğine sahip mobil ve gömülü görüntü uygulamalarının tasarım

gereksinimlerini kolayca karşılayabilen, çok küçük, düşük gecikmeli bir model ortaya konulmuştur.

MobileNet mimarisi görüntülerden evrimsel filtrelerle özellik çıkarımı aşamasında, standart konvolüsyonel operasyonu yerine Derinlemesine Ayrılabilir Evrişimler (DAE) (Depthwise Separable Convolutions) olarak adlandırılan bir yöntem kullanır. DAE'nin temel dayanağı, tam bir evrişim operatörünü, evrişimi iki ayrı katmana bölen faktörleştirilmiş bir sürümle değiştirmektir. Standart bir evrişim, girdileri tek adımda yeni bir dizi çıktıda hem filtreler hem de birleştirir. DAE ise, bunu iki katmana böler, filtreleme için ayrı bir katman ve birleştirmek için ayrı bir katman kullanır. İlk katmana derinlemesine evrişim denir. Bu katmanda giriş kanalı başına tek bir evrişim filtresi uygulanarak hafif filtreleme gerçekleştirir. İkinci katmanda giriş kanallarının doğrusal kombinasyonlarını hesaplayarak yeni özellikler oluşturmaktan sorumlu olan noktasal evrişim adı verilen 1×1 boyutunda evrişim uygulanır. Derinlemesine evrişim, standart evrişime göre son derece verimlidir (Howard ve diğ, 2017).


MobileNetv2 (Sandler ve diğ, 2018), MobileNetv1 ağ tasarımına dayalı olarak geliştirilmiştir. MobileNetv2 $k = 3$ (3×3 derinlikte ayrılabilir evrişim) kullanır, bu nedenle hesaplama maliyeti, doğrulukta yalnızca küçük bir azalmayla standart evrişimlerden 8 ila 9 kat daha küçüktür. MobileNetv2'de ayrıca ReLU gibi lineer dönüşüm uygulayan katmanlarında oluşan bilgi kaybını engellemek için lineer darboğaz katmanları eklenmiştir. Doğrusal katmanların kullanılması, doğrusal olmayanların çok fazla bilgiyi yok etmesini engellediği için önemlidir. Ayrıca darboğazlar arasında ResNet'teki yaklaşıma benzer şekilde kısayollar oluşturulduğu için hızlı bir hesaplama süreci de sağlanmış olur.

2.2.6 Xception

Bir evrişim katmanı, 2 uzamsal boyut (genişlik ve yükseklik) ve bir kanal boyutu ile bir 3B uzayda filtreleri öğrenmeye çalışır. Bu nedenle tek bir evrişim çekirdeği, kanallar arası korelasyonları ve uzamsal korelasyonları eş zamanlı olarak eşlemekle görevlendirilir. Inception modülünün arkasındaki fikir, bağımsız olarak kanallar arası korelasyonlara ve uzamsal korelasyonlara bakacak bir dizi işlemi çarpanlara ayırarak eşleme sürecini daha kolay ve daha verimli hale getirmektir. Daha doğrusu, tipik Inception modülü ilk önce bir dizi 1×1 evrişim yoluyla çapraz kanal korelasyonlarına bakar. Ardından girdi verilerini orijinal girdi alanından daha küçük olan 3 veya 4 ayrı


alana eşler ve bu daha küçük 3B alanlardaki tüm korelasyonları 3x3 veya 5x5 evrişimler aracılığıyla eşler (Chollet, 2017).

Bu Inception modülü, büyük bir 1x1 evrişim ve ardından çıkış kanallarının örtüşmeyen bölümleri üzerinde çalışacak olan uzaysal evrişimler olarak yeniden formüle edilebilir. Xception mimarisi bu daha güçlü hipoteze dayanan ve Inception mimarisinin “aşırı” bir versiyonu olarak önerilmiştir. Bu mimari Inception mimarisinin daha güçlü bir versiyonu olduğu için “Extreme Inception” anlamına Xception olarak adlandırılmıştır.



Şekil 2.13 : Inception mimari yapısının işleyişine dair gösterim.

Xception mimarisi, ağır özellik çıkarma tabanını oluşturan 36 evrişim katmanına sahiptir. 36 evrişim katmanı, ilk ve son modüller hariç, hepsinin çevresinde doğrusal artık bağlantılara sahip olan 14 modül halinde yapılandırılmıştır. Özetle, Xception mimarisi, artık bağlantılara sahip, derinlemesine ayrılabilir evrişim katmanlarının doğrusal bir yığınıdır (Chollet, 2017).



Şekil 2.14 : Xception mimari yapısının işleyişine dair gösterim.

2.3 Spektral İndeks

Çalışmada derin öğrenmede klasik görüntü işleme bant sayısı olan 3 banttan daha fazla bant seçilerek de uygulamalar gerçekleştirilmiştir. Sınıflandırmada girdi verileri olarak kullanılacak görüntülerde tespit edilmek istenen sınıfları daha iyi tahmin etmek için ilgili spektral indeks (indisler) (Çizelge 2.5.) kullanılmış ve veri setinde katman olarak diğer bantlarla birleştirilmiştir. Bu durumda, Sentinel veri seti 5 bant ve 7 bant olmak üzere iki farklı şekilde hazırlanmıştır.

2.3.1 Normalize edilmiş vejetasyon fark indeksi (NDVI)

NDVI'da sağlıklı bitki örtüsü görünür alanda daha fazla kırmızı ışığı emerken, sağlıklı olmayan bitki örtüsü sağlıklı bitki örtüsünden daha yüksek yansımaya sahiptir. NDVI değerleri -1 ile 1 arasında değişmektedir. NDVI ayrıca küresel ölçekte kuraklık izleme için kullanılmaktadır ve oldukça yaygın bir kullanıma sahiptir. NDVI, bitki örtüsünü yapay alanlardan ayırt etmek için iyi bir göstergedir. Çalışmada hem beş bantlı, hem de yedi bantlı veri setlerinde kullanılmıştır.

2.3.2 Basit oran indeksi (SR)

Bant oran indislerinden biri olan Simple Ratio (SR), yakın kızılötesi (NIR) bantta kaydedilen yansıma ile kırmızı bantlar arasındaki oran ile hesaplanan bir spektral oran indeksidir. Görüntülerde yeşil yapraklı nesneleri diğer nesnelerden ayırt etmek için kullanılır. Yeşil yaprak nesnelerin kırmızı bölgede düşük yansıma değerlerine sahiptir, ancak sensörlerin NIR bölgesindeki nesneler daha yüksek yansıma değerlerine sahiptir. Toprak bölgelerinin ve çıplak arazilerin yaklaşık 1 SR değerlerine sahip olması beklenir. Ancak yeşil yaprak nesnelerinin SR değerleri 1'den çok daha büyük olması beklenmektedir. Ek olarak, SR indeksi görüntülerdeki bağıl biyokütleyi tahmin etmek için de kullanılabilir. Bu indis uygulamada yedi-bantlı veri setinde kullanılmıştır.

2.3.3 Diferansiyel vejetasyon indeksi (DVI)

Bir bitki örtüsü indeksi olarak kızılötesi ve kırmızı bant farkı (Tucker, 1979) toprak ve bitki örtüsü bölgeleri arasında ayırım yapabilir. Yedi bantlı veri setinde DVI kullanılarak veri seti oluşturulmuştur. İndeks, geçirimsiz yüzey ve ekilmemiş toprak alanlarını ayırt etmeye yardımcı olabilmektedir. Uygulamada SR ile uyumlu bir sonuç

verdiği gözlenmiştir. Çalışmada geçirimsiz yüzey bölgeleri yapay yüzeyler sınıfına, ekilmeyen topraklar ise orman ve yarı doğal alanlar sınıfına aittir.

Çizelge 2.5 : Çalışmada kullanılan multi-spektral indisler.

Spektral İndis	Formül	Yayın
NDVI	$\frac{NIR_{B8} - R_{B4}}{NIR_{B8} + R_{B4}}$	Rouse, Haas, Schell, ve Deering (1974)
DVI	$NIR_{B8} - R_{B4}$	Richardson ve Wiegand (1977)
SR	$\frac{NIR_{B8}}{R_{B4}}$	Pearson ve Miller (1972)

2.4 Nesne Tabanlı Görüntü Analizi

UA teknolojileri, çevresel izleme için yaygın şekilde kullanılmaktadır. Bu uygulamalara kentleşme, ormancılık, tarımsal izleme vb. dahildir. UA uygulamaları, sınırların algılanmasında da etkilidir. Gelişen teknoloji ile tematik ve topografik haritalarının üretiminde çok yüksek çözünürlüklü ve orta çözünürlüklü görüntüler de tercih edilmektedir. Bu işlemler sınıflandırmayı içerir. Sınıflandırma yöntemleri çeşitlidir, türünün seçimi söz konusu uygulamaya da bağlıdır. Bu bağlamda, piksel tabanlı analizin bazı sınırlamaları vardır. Piksel tabanlı görüntü analizi kullanımına alternatif olarak, daha yüksek çözünürlüklü görüntüler için bazı yeni perspektifler sürekli olarak geliştirilmektedir. Nesne tabanlı görüntü analizi (NTGA) özellikle yüksek çözünürlüklü görüntüler için tercih edilmektedir. Nesne tabanlı görüntü analizi, çeşitli bölütleme türlerini ve nesne tabanlı sınıflandırma işlemlerini içerir. İlgili pikselleri gruplamak için bölütleme adımı gereklidir. Görüntü bölütleme, bölümlerin geometrik, topolojik ve/veya dokusal özelliklere göre uzaysal ve spektral olarak gruplandırılmış pikseller olarak çıkarılmasını içerir (Schöpfer ve diğ, 2010). Bölütlemeye dayalı sınıflandırma, uygulamaların sonuçlarına göre normal piksel tabanlı yöntemler karşılaştırıldığında daha iyi sonuçlar vermektedir (Blaschke, 2010). Ayrıca, uygulamaya göre bölütleme parametreleri NTGA uzmanı tarafından değiştirilir.

2.5 Çoklu-Çözünürlüklü Bölütleme (Multi-Resolution Segmentation)

Baatz ve diğ. (2000) tarafından önerilen çoklu-çözünürlüklü bölütleme (ÇÇB) algoritması piksel-tabanlı görüntü işleme algoritmalarına bir alternatiftir. Literatürde ÇÇB yaygın olarak kullanılan bir bölütleme algoritmasıdır (Hossain ve Chen, 2019). ÇÇB tekniği spektral özelliklere dayanmaktadır. Bölütleme, görüntüleri parçalara ayırma yöntemidir. Bir görüntüyü nesnelere bölmek, nesnelerden öznitelikler çıkarmak ve ardından öznitelikleri sınıflandırarak görüntüyü yorumlamak bu yaklaşımın ana fikridir (Wang, 2008). Piksel tabanlı algoritmalara alternatif olarak bir görüntüyü anlamlı nesnelere bölerek şekil, doku ve bağlamsal (contextual) ayrıntılar gibi daha tanımlayıcı nitelikler geliştirebilir (Tian ve Chen, 2007). Amacı konumsal özelliklerin ve bağlamın (context) daha ileri sınıflandırılması için uygun görüntü nesneleri üretme (bölütleme aşaması) kısmı NTGA'nın (literatürdeki kısaltmasıyla OBIA) önemli bir bileşenidir (Ghorbanzadeh ve diğ, 2021). Çoklu çözünürlüklü bölütleme algoritmasında, benzer piksellerin nesneler (bölütler) halinde gruplandırılması, görüntü katmanlarının ayarlanabilir spektral değerlerine ve ölçek, şekil ve kompaktlığa göre belirlenir. Bölütlerin (segmentlerin) büyümesi parametreler kullanılarak sınırlandırılabilir. Algoritma, boyuta göre ağırlıklandırılmış görüntü nesnelerinin ortalama heterojenliğini en aza indirmek için bir birleştirme işlemi içerir (Tian ve Chen, 2007). Nesnelerin belirlenmesinde belirlenen parametrelerden şekil ve renk ağırlık değerleri birbirini tamamlar ve bu ağırlıkların toplamı 1'e eşittir. Benzer şekilde, kompaktlık ve düzgünlük değerlerinin toplamı 1'dir ve bu parametrelerin her birinin değerleri 0 ile 1 arasında değişir. Birleştirme maliyet fonksiyonu işlemi, spektral ve şekil heterojenliğini birleştirmesi Eşitlik 2.4'te (Wang, 2008) gösterilmiştir.

$$f = w \times h_{renk} + (1 - w) \times h_{biçim} \quad (2.4)$$

Eşitlikte w değeri, 0-1 aralığında spektral heterojenlik ağırlığına aittir; $h_{biçim}$ ve h_{renk} sırasıyla şekil ve renk parametrelerini ifade eder. Literatürde de birçok çalışmada, çoklu çözünürlüklü bölütleme uygulaması tercih edilmektedir (Roni ve Jia, 2020; Lang ve diğ, 2019; Tetteh ve diğ, 2020; Wang ve diğ, 2020; Ding ve diğ, 2020; Kavzoglu ve Tonbul, 2018). Algoritma, uzaktan algılama uygulamalarında yaygın bir etkiye sahiptir ve kullanımı devam etmektedir.

2.6 Çoğunluk Oylama (Majority Voting)


ESA-ÇÇB modelinde, sınıf kategorisi, ÇÇB tarafından bölümlere ayrılan her nesnedeki pikseller tarafından oylanır. Görüntüler, ÇÇB ile nesneler olarak ayrılır. Bir segment, n sayıda piksel içerir. Semantik segmentasyon ile semantik etiketlemeden sonra bir sınıf kategorisi (Cat_m) vardır. S_c NTGA sonucu elde edilen bölütleri, p pikseli ve t çoğunluk oranı kararını belirlemek için kullanılan eşik değeri ifade etmektedir. Matematiksel modelin formülleri Eşitlik (2.5)–(2.8)'da gösterilmiştir. p_{Cat} , pikselin sahip olduğu sınıfı ifade etmektedir.

$$Cat_m = Cat_1 || Cat_2 || \dots || Cat_r \quad (2.5)$$

$$S_c = S_1 || S_2 || \dots || S_c, \quad (2.6)$$

$$H_i = \frac{n_{Cat_m \in S_c}}{\sum_{i=1}^m n_{Cat_i \in S_c}} \quad (2.7)$$

$$\text{Eğer } H_i \geq t \text{ ise } \forall p_{Cat} = Cat_m, p \in S_c \quad (2.8)$$



Şekil 2.15 : Çoğunluk oylama ile semantik segmentasyonun şemasal gösterimi.

H_i , nesne için çoğunluk kategorisini ifade eder ve her nesne (object) için hesaplanır. Bir nesne, belirtilen t değerine sahip bir kategoride çoğunluğu sağlayamazsa, o nesnedeki tüm piksellerin sınıfları aynı kalacaktır. Bu nedenle, bu uygulama her nesne

için yapılan yeni bir kategori hesaplamasını temsil eder. Nesnedeki her piksel, bu işlemler sonucunda içerdiği nesnenin yeni kategori değerini alır. Böylece, ESA tabanlı sınıflandırma, ÇÇB tabanlı çoğunluk oylamasıyla rafine edilir (Şekil 2.15).

2.7 Mc-Nemar Testi

Araştırmadan elde edilen değerlerin veya bulguların istatistiksel olarak anlamlı olup olmadığını test etmek için kullanılan yöntemlerden biri McNemar testidir (McNemar, 1947). Eşitlik 2.7'deki iki oran arasındaki farkın istatistiksel önemi, bağımlı değişkenler için McNemar testi kullanılarak ölçülebilir. McNemar testi ki-kare dağılımına bağlıdır ve hesaplamalarda 2×2 boyutlu bir hata matrisi kullanır (Foody, 2004). Görüntü sınıflandırma yöntemi ile yapılan tematik haritalama çalışmalarında öncelikle farklı sınıflandırıcılar için doğruluk değerlendirmesi yapılır. Daha sonra, doğruluk hesaplamaları arasındaki farkın istatistiksel önemi, kappa katsayısı ve McNemar testi (Foody, 2004) kullanılarak belirlenebilir. McNemar test değerinin hesaplanması Eşitlik (2.7)'de gösterilmektedir, burada f_{12} ve f_{21} yanlış sınıflandırılan ($i, j = 1, 2$) örnek sayısını gösterir (Çizelge 2.6) ve hesaplamalarla χ^2 değeri elde edilir.

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{(f_{12} + f_{21})} \quad (2.7)$$

Bu analiz için, her modelin çalışma sonuçları ve farklı test bölgeleri için referans veriler kullanılarak 2×2 olasılık (contingency) matrisi (Çizelge 2.6) hesaplanmıştır. Hesaplanan χ^2 değeri McNemar test tablosundaki χ^2 değerinden büyükse H_0 hipotezi reddedilir. Hesaplama ile bulunan χ^2 değeri McNemar test tablosundaki χ^2 değerinden küçükse H_0 hipotezi kabul edilir. Tablo değerleri sabittir; örneğin, %95 doğruluk güveni için; tablo değeri 3,841'dir. H_0 boş hipotezi reddedilmediyse, eşleştirilmiş modeller aynıdır veya iki modelden hiçbiri diğerinden daha iyi performans göstermez. Bu nedenle, H_0 hipotezi reddedilmediyse, iki yöntemin önemli bir farkı olmadığı anlamına gelir. Öte yandan, H_1 hipotezi reddedilmediyse iki model arasında anlamlı bir fark vardır.

Çizelge 2.6 : İki model arasında olasılık (contingency) matrisi genel gösterimi.

		Model 1	Model 2
		Doğru	Yanlış
Model 1	Doğru	f_{11}	f_{12}
Model 2	Yanlış	f_{21}	f_{22}




3. UYGULAMA

Uygulamalar, i7 işlemci 7700HQ 2.8GHZ, 16GB RAM ve GTX1050Ti 4GB ekran kartına sahip bir bilgisayar ile gerçekleştirilmiştir. ESA uygulamaları MATLAB ortamında geliştirilmiştir. Çoklu-çözünürlüklü bölütleme algoritması eCognition yazılımı kullanılarak gerçekleştirilmiştir.

3.1 Sentinel-2 Veri Setinin Deneysel Sonuçları

Bu çalışma, arazi örtüsü haritalama sürecinin doğruluğunu ve otomasyonunu iyileştirmek için ÇÇB uygulamasını birleştiren ESA tabanlı modelleri kullanarak arazi örtüsü haritaları üretmeyi amaçlamaktadır. ESA-ÇÇB modeli iki ana adımdan oluşur: ESA tabanlı arazi örtüsü sınıflandırması ve çoklu çözünürlüklü bölütleme (ÇÇB) ile sınıflandırma performansının iyileştirilmesi. ESA-ÇÇB modeli, U-Net ve SegNet ESA algoritmalarını içerir. Piksel tabanlı yaklaşımda karşılaşılan gürültü gibi sorunlar nesne tabanlı teknik ile azaltılır. Bu yaklaşımla, ESA sonucunda oluşturulan segmentlerin her biri bir nesne olarak değerlendirilir. Bir nesnenin içindeki ağırlıklı piksel etiketi, tüm nesneye yayılır. Derin öğrenme ve çoklu çözünürlüklü bölütleme bir araya getirilerek sınıflandırma doğruluğu artırılır (Atik ve İpbüker, 2021a).



Şekil 3.1 : Sentinel veri seti akış diyagramı.

Derin öğrenme tabanlı görüntü sınıflandırması ve ESA-ÇÇB modelini kullanan önerilen yaklaşım, beş ve yedi bantlı birleştirilmiş katmanların oluşturduğu görüntüler ile iki farklı test alanı alanına uygulanmıştır. Bu işlemler 32×32 , 64×64 ve 128×128 olmak üzere üç farklı görüntü parçacığı boyutu için gerçekleştirilmiştir. Deneyde her model için optimum görüntü parçacığı boyutu aranmıştır. Sentinel veri seti yaklaşık olarak %17 doğrulama, %15 test ve %68 eğitim verisi içermektedir. Bu uygulamada, 128×128 görüntü parçacığı için 16 yığın boyutu, 64×64 görüntü parçacığı için 32 yığın boyutu ve 32×32 görüntü parçacığı için 128 yığın boyutu kullanılmıştır. Optimizasyon algoritması olarak stokastik gradyan descent (SGD) kullanılmıştır. Uygulamada 0.01 başlangıç öğrenme oranı (learning rate) uygulanmıştır. Her deney için, derin öğrenme tabanlı modeller için farklı ve uygun epok sayıları kayıp fonksiyonuna göre erken durdurma ile belirlenmiştir. ÇÇB algoritması, Sentinel-2 veri seti için 65 ölçek, 0.3 şekil ve 0.5 kompaktlık parametreleri ile gerçekleştirilmiştir. Önerilen yaklaşım ile sınıfı belirlemek için optimum eşik değeri (t); Sentinel-2 veri seti için %40 şeklinde deneysel olarak belirlenmiştir.

Türkiye'nin en kozmopolit şehri olan İstanbul yaklaşık 75 km^2 lik bir alanı kaplamaktadır. İlk test alanı, üç eğitim görüntüsü ve bir doğrulama görüntüsü ile aynı şehirden seçilmiştir. Çizelge 3.1 – Çizelge 3.8'da, yapay yüzeyler sınıfını (YY), orman ve yarı doğal alanlar sınıfını (YDA) ve su yapıları sınıfını (SY) göstermektedir. Genel doğruluk (GD) ve ortalama F1 skoru (Or. F1) ve Kappa istatistik değerleri de gösterilmektedir. IoU ise Intersection over Union ölçütüne aittir.

Çizelge 3.1 : 5 bantlı İstanbul test alanı: U-Net ile değerlendirme ölçütleri.

Sınıf	U-Net Model						ESA (U-Net)–ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%
YY	75.57	86.39	90.45	90.63	71.99	84.67	94.73	95.00	95.22	96.02	90.46	92.52
YDA	78.03	66.58	86.19	77.41	73.39	60.28	93.70	86.34	94.52	89.43	88.69	79.15
SY	75.54	93.42	93.82	93.51	75.19	93.81	98.34	99.51	98.43	99.31	97.58	99.25
GD	90.16		93.39		88.65		96.59		97.31		94.78	
Or. F1	76.38		90.15		73.52		95.59		96.06		92.24	
Kappa	80.40		86.85		76.87		93.16		94.66		89.38	

Çizelge 3.2 : 5 bantlı İstanbul test alanı: SegNet ile değerlendirme ölçütleri.

Sınıf	SegNet Model						ESA (SegNet)–ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	71.14	82.16	83.21	86.79	43.73	70.60	86.64	92.19	90.19	93.64	59.11	79.37
YDA	70.89	54.77	84.56	72.67	51.36	53.67	82.74	79.38	89.76	85.33	60.46	65.12
SY	65.35	76.46	61.15	84.82	72.79	83.46	87.01	90.75	80.69	96.09	92.35	93.46
GD	85.71		90.56		79.41		94.09		95.70		86.43	
Or. F1	69.13		76.31		55.96		85.46		86.88		70.64	
Kappa	69.98		81.97		64.73		88.18		91.66		75.95	

İstanbul şehri test alanı için beş bantlı veri seti sonuçlarına göre en yüksek toplam doğruluk değeri %97,31 ile 64×64 görüntü parçacığı boyutuna U-Net mimarisini kullanan ESA-ÇÇB modeli ile elde edilmiştir (Çizelge 3.1). İstanbul test sitesi için en düşük genel doğruluk %79,41 ile 128×128 görüntü parçacığı boyutuna sahip SegNet modeli ile elde edilmiştir (Çizelge 3.2). Bireysel sınıf F1 skoru için en yüksek performans, su yapıları sınıfı için yapılan deneyde 64×64 görüntü parçacığı boyutuna sahip ESA (U-Net)-ÇÇB modeli ile %98,43 olarak elde edilmiştir (Çizelge 3.1). En düşük F1 skoru, %51,36 ile orman ve yarı doğal sınıf için 128 × 128 görüntü parçacığı boyutundaki SegNet modelinden elde edilmiştir (Çizelge 3.2). Sınıf başına en iyi IoU değeri, su yapıları sınıfı için 32 × 32 görüntü parçacığı boyutuna sahip ESA (U-Net)-ÇÇB modeli için %99,51 olarak bulundu (Çizelge 3.1). En düşük IoU değeri, orman ve yarı doğal alanlar sınıfı için 128 × 128 görüntü parçacığı boyutuna sahip SegNet modeli için %53,67 ile bulunmuştur (Çizelge 3.2). Ayrıca, tüm ESA-ÇÇB model sonuçlarının temel ESA tabanlı modellerden daha iyi olduğu semantik segmentasyon sonuçlarında da ortaya konulmuştur.

İstanbul test alanında (Şekil 3.2), yedi bantlı veri seti için en yüksek performansın 128×128 görüntü parçacığı boyutuna sahip ESA (SegNet)-ÇÇB modeli ile elde edilmiştir. Bu modelde toplam doğruluk oranı %97,09 ve kappa oranı %94,40 olduğu ve 32 × 32 görüntü parçacığı boyutuna sahip ESA (U-Net)-ÇÇB modelinin ortalama F1 skoru %94,68'dir (Çizelge 3.3 ve Çizelge 3.4). Yine aynı model, sınıf ölçütleri olarak yapay yüzeyler ve orman ve yarı doğal alanlar sınıfları için en yüksek doğrulukları vermiştir. Su yapıları sınıfı için en yüksek performans gösteren model, 128 × 128 görüntü parçacığı boyutuna sahip aynı modeldir. En düşük performans sonuçları, genel doğruluk için 32 × 32 görüntü parçacığı boyutu için %89.23, ortalama F1 skoru %71.74 ve kappa katsayısı %80.12 ile SegNet modeli için bulunmuştur (Çizelge 3.4). Tablolarda genel doğruluk (GD), F1 skoru, Intersection over Union (IoU), Ortalama F1 (Or. F1) ve Kappa ölçütleri ile modellerin performans değerlendirilmesi yapılmıştır.


Çizelge 3.3 : 7 bantlı İstanbul test alanı: U-Net ile değerlendirme ölçütleri.

Sınıf	U-Net Model						ESA (U-Net)-ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	89.12	89.53	88.27	89.12	61.83	78.66	93.34	94.70	90.82	93.66	89.71	93.19
YDA	84.84	74.53	80.91	71.61	70.40	61.19	92.47	85.81	88.63	82.18	88.45	84.80
SY	94.07	90.77	94.54	92.91	78.53	92.05	98.22	97.79	98.48	98.93	96.68	98.93
GD	92.48		92.05		85.38		96.31		95.55		95.57	
Or. F1	89.34		87.91		70.25		94.68		92.64		91.61	
Kappa	84.76		83.81		73.36		92.59		91.00		91.55	


Çizelge 3.4 : 7 bantlı İstanbul test alanı: SegNet ile değerlendirme ölçütleri.

Sınıf	SegNet Model						ESA (SegNet)-ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%	F1%	IoU%
YY	74.74	84.23	89.89	89.67	84.07	88.03	85.81	91.75	93.05	95.03	92.57	95.56
YDA	74.93	70.45	90.12	75.07	83.81	74.44	84.86	82.41	91.67	86.95	93.37	89.79
SY	65.55	87.77	81.02	89.88	69.23	90.06	84.42	97.49	98.57	98.02	94.08	98.33
GD	89.23		92.49		91.60		94.60		96.57		97.09	
Or. F1	71.74		87.01		79.04		85.03		94.43		93.34	
Kappa	80.12		84.99		84.03		89.80		93.17		94.40	

AKAÖ sınıfları, önerilen model olan ESA-ÇÇB modeliyle temel ESA modellerinden daha iyi tahmin edilmiştir. Özellikle 128×128 görüntü parçacığı boyutuna sahip U-Net modeli için sonuç güçlü bir tuz-biber (salt-pepper) etkisine sahiptir (Şekil 3.3). Sınıflandırma sonucunda gürültü olarak kabul edilen tuz-biber etkisi değerlendirme ölçütlerindeki değerleri de olumsuz yönde etkilemektedir. Uygulamada kullanılan ESA-ÇÇB modeli, sonuçların büyük ölçüde iyileştirilmesine yardımcı olmuştur. Boğaz üzerindeki köprü yapay bir yüzey sınıfı olarak bazı modellerin sonuçlarında sınıflandırmada elde edilememiştir. Köprü, 32×32 ve 64×64 görüntü parçacığı boyutlarına sahip ESA (U-Net)-ÇÇB modeli ve 64×64 görüntü parçacığı boyutlarına sahip ESA (SegNet)-ÇÇB modeline göre ayırt edilmiş ve sınıflandırılmıştır. İstanbul test sahası alanı için beş ve yedi-bantlı veri setlerinin arazi örtüsü sınıflandırma sonuçları sırasıyla Şekil 3.3 ve Şekil 3.4'te gösterilmektedir.




Şekil 3.2 : İstanbul test alanı orijinal (sağda) ve referans görüntüleri (solda).




(a) U-Net

(b) ESA(U-Net)+ÇÇB


Şekil 3.3 : 5-bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a-d: 32×32 görüntü parçacığı; e-h: 64×64 görüntü parçacığı; i-l: 128×128 görüntü parçacığı).




(c) SegNet




(d) ESA (SegNet) + ÇÇB




(e) U-Net




(f) ESA(U-Net)+ÇÇB




(g) SegNet



(h) ESA (SegNet) + ÇÇB




(i) U-Net




(j) ESA(U-Net)+ÇÇB


Şekil 3.3 (devam) : 5-bant veri seti ile ESA ve ESA–ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).



Şekil 3.3 (devam) : 5-bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).



Şekil 3.4 : 7-bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).



Şekil 3.4 (devam) : bant veri seti ile ESA ve ESA-ÇÇB modellerinin İstanbul test alanı sonuçları (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).

Diğer test alanı ise eğitim safhasında kullanılmayan Kocaeli şehrinden seçilmiştir (Şekil 3.5). Böylece eğitilen modellerin farklı test alanlarında uygulanabilirliği araştırılmıştır. Bu bölgeye ait test uygulaması ile çalışmada kapsamındaki hedeflerden biri gerçekleştirilmiştir. Semantik segmentasyon ile AKAÖ sınıfları üreten çalışma kapsamındaki modellerin eğitim için seçilen alanlar dışında da işlevli ve çalışır olduğu gösterilmek istenmiştir. Açık paylaşılan veri setlerinde bunu araştırmak daha zorken, çalışma kapsamındaki uygulama için kullanılan bu veri seti ile yapılan test uygulaması ile (Sentinel, 5 bant ve 7 bant), önerilen modelin, eğitim sahası dışında da başka alana adapte edilebilirliği gösterilmiştir. Bu adapte edilebilirlik, test sonuçlarının değerlendirme ölçütlerinin değerleri ile ortaya konmuştur.

Kocaeli test alanı sonuçları, İstanbul test sahasının sonuçlarıyla karşılaştırılabilme imkânı elde edilmiştir. Kocaeli ilinde en yüksek genel doğruluk sonucu, beş-bantlı veri seti ve 32×32 görüntü parçacığı boyutu ile ESA (U-Net)–ÇÇB modeli için %98,44 olarak bulunmuştur (Çizelge 3.5). En düşük doğruluk sonucu, beş bantlı veri setinin SegNet modeli 32×32 görüntü parçacığı boyutu kullanılarak %89.85 olarak bulunmuştur (Çizelge 3.6). Aynı şekilde, doğruluk değerlendirme tablolarında görüldüğü üzere, sınıflandırma doğruluğunda, beş-bantlı veri seti ile Kocaeli test sahası modellerinin sonuçlarında ayırt edilebilir farklılıklar bulunmuştur (Şekil 3.6). SegNet ve ESA (SegNet)–ÇÇB modelleriyle semantik segmentasyon sonuçlarında liman genellikle minimize edilmiştir veya yoktur. Yapay yüzeyler ile orman ve yarı doğal alan sınıfları için genel doğruluk açısından en başarılı yöntem, 32×32 görüntü parçacığı boyutunu kullanan ESA (U-Net)–ÇÇB modelidir.

Kocaeli test sahası alanında, 64×64 görüntü parçacığı boyutunu kullanan ESA (SegNet)–ÇÇB modelleri, tüm değerlendirme ölçütleri için en yüksek değerlere sahiptir (orman ve yarı doğal alanlar sınıfının IoU değeri hariç). Son olarak, bu sonuçlar aracılığıyla, ESA'lara dayalı güncel modellerin sonuçlarının ESA-ÇÇB modeli kullanılarak iyileştirildiği ortaya konmuştur. En düşük doğruluklu değerler 32×32 ve 128×128 görüntü parçacığı boyutlarına sahip SegNet modeli ile elde edilmiştir. Ayrıca, bu deneylerin sonucuna göre bir tek optimum ESA tabanlı bir model yoktur. Bu, veri kümesine ve test alanı alanına göre değişim göstermektedir.

Çizelge 3.5 : 5 bantlı Kocaeli test alanı: U-Net ile değerlendirme ölçütleri.


Sınıf	U-Net Model						ESA (U-Net)–ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	73.72	83.74	87.73	88.21	67.59	80.49	93.81	95.35	91.76	94.27	86.51	92.73
YDA	66.07	76.05	73.47	85.05	59.31	69.94	88.87	92.80	88.42	92.01	81.18	88.41
SY	87.33	98.48	95.56	97.75	86.67	98.73	97.63	99.40	98.98	99.36	97.43	99.48
GD	94.43		96.01		93.22		98.44		98.17		97.60	
Or. F1	75.71		85.59		71.19		93.42		96.46		88.37	
Kappa	90.88		93.50		88.86		97.44		97.01		96.07	

Çizelge 3.6 : 5 bantlı Kocaeli test alanı: SegNet ile değerlendirme ölçütleri.


Sınıf	SegNet Model						ESA (SegNet)–ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	52.00	73.85	84.46	84.78	59.27	72.65	83.28	88.41	88.06	91.31	72.70	80.45
YDA	47.56	62.88	75.84	80.97	53.23	67.73	80.07	88.33	84.47	89.54	60.39	78.11
SY	74.52	94.69	76.71	96.67	70.52	95.76	91.44	97.26	89.62	98.54	89.93	97.99
GD	89.85		94.72		90.48		96.27		97.24		93.94	
Or. F1	58.03		79.00		61.01		84.93		87.38		74.34	
Kappa	83.43		91.79		84.57		93.93		95.48		90.16	




Şekil 3.5 : Kocaeli test alanı orijinal (sağda) ve referans görüntüleri (solda).




(a) U-Net




(b) ESA(U-Net)+ÇÇB




(c) SegNet



(d) ESA (SegNet) + ÇÇB




(e) U-Net



(f) ESA(U-Net)+ÇÇB

Şekil 3.6 : Beş bantlı veri setine sahip ESA modelleri ve ESA-ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).



Şekil 3.6 (devam): Beş bantlı veri setine sahip ESA modelleri ve ESA–ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).

Gözlenebilir semantik segmentasyon sonuçları, yedi bantlı veri seti ile Kocaeli test alanı için gösterilmektedir (Şekil 3.7). Yedi bantlı veri seti ile bu bölge için aynı modellere sahip beş-bantlı veri seti arasında önemli farklılıklar olduğu gözlenmiştir. Bu deneyde 64×64 görüntü parçacığı boyutuna sahip ESA (SegNet)–ÇÇB modeli (önerilen model) diğer modellere göre daha üstün sonuçlar vermiştir. U-Net modelleri ile daha ayrıntılı sonuçlar elde edilmiş ve bu, bazı görüntü parçacığı boyutlarında daha güçlü bir tuz-biber (salt-pepper) etkisine neden olduğu görülmüştür. SegNet modelleri,

bu deneyde semantik segmentasyon ile sınıflandırmada genel olarak daha düzgün sınıf geçişleri gösterdiği gözlenmiştir.



Çizelge 3.7 : 7 bantlı Kocaeli test alanı: U-Net ile değerlendirme ölçütleri.

Sınıf	U-Net Model						ESA (U-Net)-ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	82.74	84.99	70.06	82.92	66.71	76.76	88.64	91.89	85.27	91.30	89.76	89.39
YDA	74.80	85.85	68.62	83.17	62.74	71.41	89.72	93.31	81.69	91.34	76.51	85.60
SY	86.48	95.53	59.34	94.55	92.66	98.13	93.85	97.49	93.04	97.56	98.38	99.44
GD	94.92		93.98		92.36		97.42		97.14		96.70	
Or. F1	81.34		66.01		74.04		90.74		86.67		88.22	
Kappa	91.77		90.23		87.62		95.81		95.35		94.62	

Çizelge 3.8 : 7 bantlı Kocaeli test alanı: SegNet ile değerlendirme ölçütleri.

Sınıf	SegNet Model						ESA (SegNet)-ÇÇB					
	32 × 32		64 × 64		128 × 128		32 × 32		64 × 64		128 × 128	
	F1 %	IoU%	F1%	IoU%	F1%	IoU%	F1 %	IoU%	F1%	IoU%	F1%	IoU%
YY	80.10	81.82	90.37	88.68	83.94	85.05	87.77	88.76	92.50	94.37	90.26	92.29
YDA	59.14	77.78	85.53	86.24	79.72	83.31	83.83	86.37	88.94	92.07	87.64	90.92
SY	44.97	96.39	91.34	97.92	76.46	97.44	94.07	99.06	96.19	99.20	90.34	98.84
GD	93.67		96.29		95.25		96.60		98.16		97.62	
Or. F1	61.40		89.08		80.04		88.56		92.54		89.41	
Kappa	89.73		93.93		92.22		94.46		96.98		96.11	


ESA-ÇÇB modellerinin sonuçları, ayrı ayrı sınıf ölçütleri de dahil olmak üzere (F1 ve IoU) en yüksek doğruluğu 5 bantlı veri setinde elde edilmiştir. Genel doğruluk %98,44 ve kappa katsayısı %97,44 ile 32×32 görüntü parçacığı boyutuna sahip U-Net ile önerilen yaklaşım sonuçları en yüksek değerlerdir (Çizelge 3.5). Ortalama F1 skoru için, aynı modele sahip 64×64 görüntü parçacığı boyutu, %96,46 ile en yüksek sonucu vermiştir. Bu değerlendirme ölçütleri için elde edilen en düşük sonuçları, 32×32 görüntü parçacığı boyutuna sahip SegNet modeli kullanılarak elde edilmiştir (Çizelge 3.7).

Bireysel sınıflar için F1 skoru ve IoU sonuçları farklı doğruluk değerlendirme ölçütleri olarak gösterilir. Tüm test sonuçlarına göre ayrı sınıflar için en iyi değerler ESA-ÇÇB model performanslarına aittir. ESA-ÇÇB modelleri, ESA tabanlı modellerle (U-Net ve SegNet) nicel olarak karşılaştırılmıştır. (Çizelge 3.4 - Çizelge 3.8). En iyi sınıflandırma performanslarına sahip olan ESA-ÇÇB modelleri (önerilen yaklaşım) önemli bir üstünlük göstermiştir. Yedi-bantlı veri setinin sonuçları Çizelge 3.7 ve Çizelge 3.8’de gösterilmektedir.

Dengesiz (imbalanced) bir veri setinde değerlendirmeyi anlamak için belirli bir metriği uygulamak yeterli olmayabilir. Bunun yanı sıra, model performanslarını daha ayrıntılı gözlemlemek için farklı değerlendirme ölçütlerinde de incelemek gerekebilir. Bu nedenle, çalışmanın sonuçları sınıf düzeyinde sınıflandırma doğruluğu seçilen ek bazı ölçütlerle de incelenmiştir. Her bir sınıfın kesinlik (precision) ve duyarlılık (recall) değerleri, iki veri kümesi için farklı görüntü parçacığı boyutlarına sahip tüm sınıflandırma modeller için hesaplanmıştır. Ayrıca, çalışmanın sınıf başına F1 skorları ve ortalama F1 skoru da modellerin verimliliği hakkında gerekli bilgileri sağlamaktadır.

Genel olarak, tek tek sınıflar için kesinlik değerlerinin, her iki test alanı için duyarlılık parametresinde daha yüksek değerlere sahip olduğu görülmüştür. İstanbul test alanında, beş-bantlı veri setinde 128×128 görüntü parçacığı boyutu kullanılarak SegNet için en düşük kesinlik değerleri bulunmuştur. ESA modelleri ve ESA-ÇÇB modelleri arasında kesinlik açısından küçük bir fark vardır. ESA modelleri ile ESA-ÇÇB modelleri arasında duyarlılık (recall) parametresinde önemli bir fark vardır. Bunun nedeni olarak, duyarlılık ölçütü, elde edilen haritalarda positive tahmin edilmek istenen sınıfların ne kadar positive sınıflandırıldığı ile ilgilidir. Önerilen yaklaşımla


elde edilen haritalarda bu true positive tahminlerin oranı daha yüksek olarak elde edilmiştir. Sonuç olarak, ESA-ÇÇB modelinin duyarlılık sonuçları, tüm deneyler için temel ESA tabanlı modellerden daha iyi sonuçlar vermiştir.




(c) U-Net




(d) ESA(U-Net)+ÇÇB



(e) SegNet



(f) ESA (SegNet) + ÇÇB




(g) U-Net



(h) ESA(U-Net)+ÇÇB

Şekil 3.7 : Yedi bantlı veri setine sahip ESA modelleri ve ESA-ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32×32 görüntü parçası; e–h: 64×64 görüntü parçası; i–l: 128×128 görüntü parçası).



Şekil 3.7 (devam): Yedi bantlı veri setine sahip ESA modelleri ve ESA–ÇÇB modelleri Kocaeli test alanı sonuçları. (a–d: 32×32 görüntü parçacığı; e–h: 64×64 görüntü parçacığı; i–l: 128×128 görüntü parçacığı).

Hem beş, hem de yedi-bantlı Sentinel veri setlerinde benzer kesinlik-duyarlılık eğilimleri gözlemlenmiştir. Genel olarak, kesinlik sonuçları duyarlılık sonuçlarından daha yüksektir. Dolayısıyla F1 skorları bu çeşitliliğin yorumlanmasında belirleyici olmuştur. Her iki test sahası alanında, su kütleleri sınıfının kesinliği ve duyarlılık ölçütleri, diğer iki sınıfın sonuçlarından daha iyidir. Bunun olağan bir durum olmasının sebebi, orman ve yarı doğal alanlar sınıfı ile yapay yüzeyler sınıfı oldukça iç içe

geçmiş olmasıdır. Hata matrisinin genel gösterimi Şekil 3.8’da gösterilmiştir. Değerlendirmede kullanılan ölçütler Eşitlik 3.1 –3.6 ‘da gösterilmiştir.

Hata Matrisi		Tahmin	
		Pozitif	Negatif
Gerçek	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 3.8 : Hata matrisinin genel gösterimi değerleri.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.1)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.2)$$

$$F1 \text{ skor} = 2 \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (3.3)$$


$$IoU = \frac{TP}{TP + FP + FN} \quad (3.4)$$

$$Genel \text{ Doğruluk} = \sum_{i=1}^k \frac{N_{ii}}{N} \quad (3.5)$$


$$Kappa = \frac{n \sum_{i=1}^q n_{ii} - \sum_{i=1}^q n_{Ri} n_{ci}}{n^2 - \sum_{i=1}^q n_{Ri} n_{ci}} \times 100 \quad (3.6)$$

Eşitliklerde, gerçek pozitif (TP), tahmin edilen etiketin ve kesin doğruluk etiketinin aynı olduğu piksel sayısına karşılık gelmektedir. Yanlış-pozitif (FP) değeri ise, kesin doğruluk etiketi negatifken tahmin edilen etiketin pozitif olduğu piksel sayısına karşılık gelir. Yanlış-negatif (FN), tahmin edilen etiket negatif iken, kesinlik etiketinin pozitif olduğu piksel sayısını ifade etmektedir. IoU, diğer bir ifadeyle Jaccard indeksi, iki bölgenin üst üste örtüşmesini 0-1 aralığında ölçer.

İstanbul test alanında önerilen ESA-ÇÇB modelleri ile tüm sınıflar için duyarlılık değerleri artırılmıştır (Şekil 3.9). Kocaeli test alanı için kesinlik ve duyarlılık değerleri Şekil 3.10’de gösterilmiştir. Şekil 3.9 ve 3.10’de Öne.U, önerilen yaklaşım ESA (U-Net)–ÇÇB’yi ve Öne.S ESA, (SegNet)–ÇÇB’yi ifade etmektedir.



Şekil 3.9 : İstanbul test alanı için farklı görüntü boyutlarında kesinlik ve duyarlılık değerleri.



Şekil 3.10 : Kocaeli test alanı için farklı görüntü boyutlarında kesinlik ve duyarlılık değerleri.

3.2 McNemar Testi

Birbiriyle ilişkili iki oran arasındaki farkın önemini ölçmek için McNemar testi geliştirilmiştir. Tüm farklı yöntemlerin beş ve yedi banıtlı Sentinel veri setleri üzerindeki deneyleri için McNemar testi kullanılmıştır. Bu nedenle, farklı yöntemlerle üretilen arazi örtüsü sınıflandırmasının doğrulukları arasındaki farkın anlamlılığı McNemar testi kullanılarak istatistiksel olarak analiz edilmiştir.

Eşleştirilmiş nominal (kategorik) veriler için McNemar testi kullanılır ve uygulamada kullanılan veriler bu değerlendirme için uygundur. Bu çalışmada, tüm eşleştirilmiş


modeller H_1 hipotezine karşılık gelmektedir. α , %95 doğruluk güveni için anlamlılık düzeyi ve p McNemar testi ile hesaplanan bir değerdir. H_1 hipotezi geçerli olduğunda $p < \alpha$ için $\alpha = 0,05$ anlamlılık düzeyidir. Sentinel uygulamasında kullanılan modellerin hepsinin ikili seşkilde ki-kare değerleri hesaplanmış ve 3,841 değeri ile karşılaştırılmıştır. Sonuçlara göre, uygulamadaki tüm eşleştirilmiş modeller önemli ölçüde farklıdır ve modellerin tahmin performansı farklıdır. Temel ESA modelleri ve önerilen yaklaşım modelleri için her görüntü parçacığı boyutu (32, 64, 128) için beş ve yedi bantlı Sentinel veri kümeleri için hesaplanmıştır. McNemar testine göre Sentinel veri setinin tüm yöntemleri için veri seti H_1 hipotezi doğrudur, yani tüm yöntemlerin karşılaştırılması bilimsel olarak anlamlıdır (Çizelge 3.9).

Çizelge 3.9 : Modeller için McNemar test sonuçları.

Test Alanı	Yöntem	5-Bant			7-Bant		
		32 × 32	64 × 64	128 × 128	32 × 32	64 × 64	128 × 128
İstanbul	U-Net&U-Net-ÇÇB	40962	23308	36789	25864	23417	64731
	SegNet&SegNet-ÇÇB	54857	36063	46511	38202	28055	39722
Kocaeli	U-Net&U-Net-ÇÇB	26810	14914	28721	15360	19305	25002
	SegNet& SegNet-ÇÇB	43818	17189	22612	19273	13006	14391

3.3 Zurich Summer Veri Seti Deneysel Sonuçları

Sentinel veri setine benzer yöntem ÇYÇ görüntülerinden oluşan açık Zurich Summer veri setine de uygulanmıştır. Uygulamanın akış şeması Şekil 3.11’de gösterilmiştir.



Şekil 3.11 : Zurich Summer Veri seti uygulaması akış diyagramı.

Sonuçların nicel karşılaştırmasına göre, ESA-ÇÇB model kullanımı doğrulukları ve performans ölçütlerini artırmıştır. U-Net ve SegNet sınıflandırmasına konumsal filtre ve ÇÇB'nin uygulanması, tüm görüntü parçacığı boyutları için genel doğruluğu arttırdığı gözlenmiştir. En yüksek genel doğruluk ve ağırlıklı IoU değerleri SegNet–ÇÇB modellerine aittir (Çizelge 3.10 ve 3.11). Önerilen yaklaşımın bu iyileştirme değerleri, Sentinel veri setinde gerçekleştirilen deneylerle de uyumludur (Çizelge 3.4, 3.5 ve 3.7).


Tablolarda genel doğruluk (GD), F1 skoru, ağırlıklı Intersection over Union (IoU), Ortalama Doğruluk (mean accuracy) ölçütleri ile modellerin performans değerlendirilmesi yapılmıştır. ÇÇB algoritması, Zurich Summer veri seti için 65 ölçek, $h_{biçim} = 0.4$ ve 0.5 kompaktlık parametreleri ile gerçekleştirilmiştir. Bu uygulamada, ESA modeli sonucunda tahmin edilen pikseller, ÇÇB algoritması ile elde edilen segmentte farklı sınıflara ait olduğundan baskın sınıfı belirlemek için optimum eşik değeri (t); Zurich Summer veri seti için %80 şeklinde deneysel olarak belirlenmiştir.

Çizelge 3.10 : Zurich Summer veri seti ZH 16 görüntüsünün deneysel sonuçları.


Model	GD %	F1 skoru %	Ort. Doğ.%	Ağırlıklı IoU%
32 × 32				
SegNet	88.76	81.05	71.13	81.41
U-Net	85.49	74.04	66.08	75.57
SegNet–ÇÇB *	89.73	84.17	71.71	82.76
U-Net–ÇÇB *	85.98	76.04	66.73	76.20
64 × 64				
SegNet	90.05	74.92	75.54	82.88
U-Net	87.88	73.66	68.56	79.44
SegNet–ÇÇB *	90.91	77.29	75.87	84.15
U-Net–ÇÇB *	88.32	72.36	68.45	79.95
128 × 128				
SegNet	91.09	72.17	72.93	84.39
U-Net	89.80	69.22	68.22	82.48
SegNet–ÇÇB *	92.03	72.79	73.41	85.88
U-Net–ÇÇB *	91.04	69.05	68.94	84.29

* Önerilen yöntemin uygulanması


Uygulama dört bant kullanılarak gerçekleştirilmiştir. Literatürdeki diğer çalışmalarda olduğu gibi, sınıflandırmada arka plan (background) sınıfı dikkate alınmamıştır. ESA-ÇÇB modelinde medyan filtre boyutu 3×3 'tür. Test görüntüleri olarak ZH-16 ve ZH-17 görüntüleri, deneyler için doğrulama verileri olarak ZH-20 görüntüleri kullanılmıştır. ESA (SegNet)-ÇÇB modeli olarak önerilen yaklaşım, test görüntüleri için genel doğruluk ve ve ağırlıklı IoU ölçütlerinde açık paylaşılan bu veri setinde SegNet modelinden daha iyi performansa sahiptir (Şekil 3.12 ve 3.13 ve Çizelge 3.10 ve 3.11). ESA-ÇÇB uygulamasında, ZH-16 ve ZH-17 görüntüleri için nesne çoğunluk oyu $t = \%80$ olarak uygulanmıştır. t eşliğinin belirlenmesi görüntüye, nesne boyutuna ve sınıf karmaşıklığına bağlıdır. Bir nesnede sınıflar olarak t 'den fazla değer segmentasyon tahminleri varsa, tüm piksellere çoğunluk sınıfının aynı sınıf etiketlemesi atanır, değilse, ilk tahmin sınıfı etiketleri korunur. Böylece ESA-ÇÇB modeli ÇYÇ görüntülerden oluşan açık veri setine uygulanarak tuz-biber etkisi azaltılmıştır (Çizelge 3.10).




Şekil 3.12 : Zurich Summer veri seti sonuçları (ZH-16): (a) orijinal görüntü; (b)referans veri; (c–f) 32×32 görüntü boyutu; (g–j) 64×64 görüntü boyutu; (k–n) 128×128 görüntü boyutu.




(c) U-Net




(d) ESA (U-Net) + ÇÇB




(e) SegNet



(f) ESA (SegNet) + ÇÇB




(g) U-Net




(h) ESA (U-Net) + ÇÇB


Şekil 3.12 (devam): Zurich Summer veri seti sonuçları (ZH-16): (a) orijinal görüntü; (b) referans veri; (c–f) 32×32 görüntü boyutu; (g–j) 64×64 görüntü boyutu; (k–n) 128×128 görüntü boyutu.




(i) SegNet




(j) ESA (SegNet) + ÇÇB




(k) U-Net



(l) ESA (U-Net) + ÇÇB



(m) SegNet



(n) ESA (SegNet) + ÇÇB

Şekil 3.12 (devam): Zurich Summer veri seti sonuçları (ZH-16): (a) orijinal görüntü; (b) referans veri; (c–f) 32×32 görüntü boyutu; (g–j) 64×64 görüntü boyutu; (k–n) 128×128 görüntü boyutu.


Çizelge 3.11 : Zurich Summer veri seti ZH 17 görüntüsü için deneysel sonuçları.

Yöntem	GD %	F1 skor %	Ort.Doğ. %	Ağırlıklı IoU%
32 × 32				
SegNet	88.48	90.92	62.88	79.73
U-Net	85.83	68.72	65.51	78.82
SegNet-ÇÇB *	89.17	91.53	62.88	80.88
U-net-ÇÇB *	86.40	69.45	65.93	75.72
64 × 64				
SegNet	90.31	75.68	59.51	82.42
U-Net	87.65	87.25	73.20	77.98
SegNet-ÇÇB *	90.67	75.78	59.56	83.00
U-Net-ÇÇB *	88.19	86.33	73.62	78.90
128 × 128				
SegNet	89.48	87.93	58.58	80.78
U-Net	85.77	84.35	72.17	75.48
SegNet-ÇÇB *	89.94	87.76	58.43	81.52
U-Net-ÇÇB *	86.33	84.66	71.80	76.40

* Önerilen yöntemin uygulanması




(a) Orijinal görüntü




(b) Referans veri


Şekil 3.13 : Zurich Summer veri seti sonuçları (ZH-17): (a) orijinal görüntü; (b) referans veri; (c–f) 32 × 32 görüntü boyutu; (g–j) 64 × 64 görüntü boyutu; (k–n) 128 × 128 görüntü boyutu.




(c) U-Net




(d) ESA (U-Net) + ÇÇB




(e) SegNet



(f) ESA (SegNet) + ÇÇB




(g) U-Net



(h) ESA (U-Net) + ÇÇB

Şekil 3.13 (devam): Zurich Summer veri seti sonuçları (ZH-17): (a) orijinal görüntü; (b) referans veri; (c–f) 32×32 görüntü boyutu; (g–j) 64×64 görüntü boyutu; (k–n) 128×128 görüntü boyutu.



Şekil 3.13 (devam): Zurich Summer veri seti sonuçları (ZH-17): (a) orijinal görüntü; (b) referans veri; (c–f) 32×32 görüntü boyutu; (g–j) 64×64 görüntü boyutu; (k–n) 128×128 görüntü boyutu.

Zurich Summer veri seti üzerinde yapılan deneyler, literatürdeki diğer güncel ESA modelleri ile karşılaştırılmıştır ve değerler % olarak verilmiştir (Çizelge 3.12). Tüm yöntemler aynı eğitim, doğrulama ve test verileri üzerinde uygulanmıştır. Bu çalışmada SegNet–ÇÇB (128×128 görüntü parçacığı) yöntemi, ZH-16 test

görüntüsünde en yüksek genel doğruluğa ve ağırlıklı IoU'ya sahipken, ZH-17 görüntüsünde en yüksek F1 skoruna sahiptir.

Çizelge 3.12 : Zurich Summer veri seti sonuçlarını literatür ile karşılaştırılması.

Yöntem	ZH-16 Test Görüntüsü			ZH-17 Test Görüntüsü		
	GD	F1 skor	A. IoU	GD	F1 skor	A. IoU
FCN (Long ve diğ, 2015)	81.02	66.13	69.92	77.14	67.42	62.81
DeeplabV3 + ResNet50 (Chen ve diğ, 2017)	88.02	69.54	79.38	89.21	81.36	80.74
DeeplabV3 + Xception (Chen ve diğ, 2018)	90.29	76.02	83.05	90.21	82.11	82.33
ESA-ÇÇB *	92.03	72.79	85.88	89.94	87.76	81.52

* Önerilen yöntemin uygulanması

3.4 Bölütleme Kalitesi

Çoklu-çözünürlüklü bölütleme parametreleri deneysel olarak belirlenebilmektedir. Literatürde bölütleme kalitesini değerlendirmek için bazı parametreler bulunmaktadır. En çok kullanılan parametreler alt bölütleme- under segmentation (US) (Clinton ve diğ, 2010) ve aşırı bölütleme- over segmentation (OS) (Clinton ve diğ, 2010) (Eşitlik (3.7), (3.8)) olarak bilinen bölütleme anomalileridir. Gerçek nesnenin birden fazla küçük alt bölüme bölünmesine aşırı bölütleme, gerçek nesnenin bir kısmının başka bir nesnenin parçası haline gelmesine alt bölütleme denir (Kavzoğlu ve Tonbul, 2018). Bu değerler, referans nesne alanı (A_r) ve bölütleme sonucunda elde edilen nesne alanının (A_b) bir fonksiyonu olarak hesaplanır. Bu çalışmada, bölütleme kalite ölçütleri olarak US, OS, Karesel ortalama hata (KOH), alan uyum indeksi (AUI), literatürdeki adıyla area fit index -AFI (Lucieer ve Stein, 2002) ve kalite oranı (KO) (quality rate) (Winter, 2000) kullanılmıştır (Eşitlik (3.7) -(3.11)). İyi bir bölütlemeye US, OS, KOH ve AUI'nin 0 olması ve KO değerinin 1 değerlerine yakın olması beklenir. Her test görüntüsü için kalite ölçütleri hesaplanmıştır (Atik ve İpbüker, 2021a). Test görüntüsünün bazı alt kümeleri Şekil 3.14 ve 3.15'de gösterilmektedir.

$$Aşırı\ bölütleme\ (OS) = 1 - \frac{A_{r(i)} \cap A_{b(i)}}{A_{r(i)}} \quad (3.7)$$


$$Alt\ bölütleme\ (US) = 1 - \frac{A_{r(i)} \cap A_{b(i)}}{A_{b(i)}} \quad (3.8)$$

$$Karesel\ ortalama\ hata\ (KOH) = \sqrt{\frac{OS^2 - US^2}{2}} \quad (3.9)$$

$$Alan\ Uyum\ İndeksi\ (AUİ) = \frac{A_{r(i)} - A_{b(j)}}{A_{r(i)}} \quad (3.10)$$

$$Kalite\ Oranı\ (KO) = \frac{A_{r(i)} \cap A_{b(i)}}{A_{r(i)} \cup A_{b(i)}} \quad (3.11)$$


Bölütleme kalite ölçütlerine göre, Sentinel veri seti, Zurich Summer veri setinden daha iyi segmentasyon kalitesine sahiptir. Bunun en önemli nedeni çözünürlük farkı ve sınıf sayısıdır. Çözünürlük ve sınıf sayısı azaldıkça bölütleme kalitesi artar. Yüksek çözünürlüklü görüntüler daha fazla ayrıntı içerdiğinden nesnelerin birbirine karışma olasılığı yüksektir. Her iki veri seti için bölütleme kalite ölçütleri Çizelge 3.13 ve Çizelge 3.14'te gösterilmektedir (Atık ve İpbüker, 2021a).



Şekil 3.14 : Sentinel veri setinden bölütleme örnekleri. Kırmızı çizgi referans nesneyi; yeşil çizgi ÇÇB segmentini ifade etmektedir.

Çizelge 3.13 : Sentinel veri seti için bölütleme kalite ölçütleri.

Görüntü	OS	US	KOH	AUİ	KO
Test Görüntüsü (İstanbul)	0.056	0.020	0.042	0.037	0.926
Test Görüntüsü (Kocaeli)	0.030	0.041	0.036	-0.012	0.931



Şekil 3.15 : Zurich Summer veri setinden bölütleme örnekleri. Kırmızı çizgi referans nesneyi; yeşil çizgi ÇÇB segmentini ifade etmektedir.


Çizelge 3.14 : Zurich Summer veri seti için bölütleme kalite ölçütleri.

Görüntü	OS	US	KOH	AUI	KO
ZH-16 Test Görüntüsü	0.071	0.021	0.053	0.051	0.910
ZH-17 Test Görüntüsü	0.085	0.015	0.061	0.071	0.881

3.5 WHUBED DeneySEL Sonuçları


Bu çalışmada, farklı konumsal çözünürlüklü görüntülere sahip WHUBED veri seti üzerinde ESA modelleri kullanılarak bina sınıfı sınıflandırılmıştır. Veri kümesi, eğitim, doğrulama ve test görüntüleri için ayrılmıştır. Öncelikle veri setindeki görüntüler DeepLabv3+ mimarisinin içinde farklı DÖ modellerinin (ResNet-18, ResNet-50, Xception, MobileNetv2) bir arada kullanılmasıyla eğitilmiştir. Eğitim esnasında uygun parametre seçimi belirlenmiş ve modeller optimize edilmiştir. ESA modellerinin eğitim aşamalarında ince ayar ve düzenlemeler (erken durdurma vb.) için validasyon doğruluğu ve kayıp fonksiyonları dikkate alınmıştır. Bu izleme ile modellerin epok numaraları da seçilmiştir. Daha sonra, her bir ESA modeli ile üretilen tahmin haritası kullanılarak sonrasında, önerilen yaklaşım uygulanmış ve sınıflandırma doğruluklarında iyileştirme gerçekleştirilmiştir. Uygulamanın son aşaması olarak arazi kullanımı sınıfına ait tematik haritalar üretilmiştir.

Çizelge 3.15’de deneysel sonuçları iki sınıfa (bina ve bina olmayan sınıfların ortalaması) aittir. Çizelge 3.15’de test görüntülerine göre değerlendirme ölçütleri ayrı ayrı gösterilmiştir. Bina olmayan sınıf, hasat edilmiş veya yeşil tarım alanları, yollar, çıplak arazi vb. gibi bir sınıftaki görüntülerdeki tüm bina dışı sınıflara karşılık gelmektedir (Atik ve İpbüker, 2020c). Çalışmanın akış diyagramı Şekil 3.16’de gösterilmiştir. Uygulamada veri setinde mevcut olan NIRRG bant kombinasyonu sınıflandırmada kullanılmıştır. Uygulamada ÇÇB algoritmasında, çoğunluk oylama aşamasında eşik değer test görüntülerinde $t=0.6$ ve 0.7 olarak uygulanmıştır. NTGA aşamasında parametrelerde ölçek=60 ve $h_{biçim}=0.25$ şeklinde uygulanmıştır. Eğitim verisi olarak, 50 görüntü ve doğrulama için 5 görüntü kullanılmıştır.




Şekil 3.16 : WHUBED veri seti uygulamasının akış diyagramı.

Test görüntüsü 055 ve 003'e ait uydu görüntüsü ve referans verisi gösterilmiştir (Şekil 3.17). ESA-ÇÇB yaklaşımı bu veri setinde de yer gerçekliğine (referans veri) daha yakın sonuçlar verdiği gözlemlenmiştir (Şekil 3.18- Şekil 3.25). Derin öğrenme tabanlı yaklaşımlar sonucu üretilen haritalarda bina sınıfındaki gürültü, ESA-ÇÇB modeli ile azaltılmış, sınıflandırma doğrulukları iyileştirilmiştir. Doğruluk ölçütlerini gösteren tablolarda genel doğruluk (GD), Ortalama Doğruluk(OD), Ortalama F1 skoru (Or. F1) ve ağırlıklı doğruluk (AD) ölçütleri ile modellerin performans değerlendirilmesi yapılmıştır.




Şekil 3.17 : Orijinal görüntüler ve referans veriler (solda 003 görüntüsü; sağda 055 görüntüsü).


003 test görüntüsünde en yüksek genel doğruluk %81.06 değeri Xception+ÇÇB ile elde edilmiştir. Ortalama doğruluk ölçütüne en yüksek değer %79.75 ile ResNet-50-ÇÇB modeline aittir. En düşük ortalama doğruluk değeri ise DeepLabV3+ MobileNetv2 modeli ile %76.04 olarak elde edilmiştir. Önerilen yaklaşım uygulandığında, bu ölçütte %1'den fazla artış sağlamıştır. Ağırlıklı doğruluk ölçütünde, Deeplabv3+Xception-ÇÇB ile en yüksek değer %66.79 olarak elde edilmiştir. F1 skor ölçütünde ise, aynı model ile %86.49 olarak en yüksek performans yine önerilen yaklaşıma aittir (Çizelge 3.15).




Şekil 3.18 : 003 görüntüsünün DeepLabV3+ ResNet-50 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).




Şekil 3.19 : 003 görüntüsünün DeepLabV3+ResNet-18 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).




Şekil 3.20 : 003 görüntüsünün DeepLabV3+Xception sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).




Şekil 3.21 : 003 görüntüsünün DeepLabV3+Mobilenetv2 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).




Şekil 3.22 : 055 görüntüsünün DeepLabV3+ResNet-50 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).



Şekil 3.23 : 055 görüntüsünün DeepLabV3+ ResNet-18 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).



Şekil 3.24 : 055 görüntüsünün DeepLabV3+Xception sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).



Şekil 3.25 : 055 görüntüsünün DeepLabV3+Mobilenetv2 sonuçları (solda ESA sonuçları; sağda ESA+ÇÇB sonuçları).

Çizelge 3.15 : 003 görüntüsüne ait ESA ve ESA+ÇÇB değerlendirme ölçütleri.


Yöntem	ESA				ESA+ÇÇB			
DeepLabV3+	GD	OD	AD	F1 skor	GD	OD	AD	F ₁ Skor
ResNet-50	80.07	79.24	65.74	83.55	80.63	79.75	66.49	84.4
Resnet-18	78.56	78.25	63.88	81.77	79.29	78.83	64.82	82.88
Xception	80.49	79.1	66.05	86.21	81.06	79.54	66.79	86.49
MobileNetv2	77.5	76.04	61.92	79.24	78.9	77.17	63.66	80.63

Çizelge 3.16 : 055 görüntüsüne ait ESA ve ESA+ÇÇB değerlendirme ölçütleri.


Yöntem	ESA				ESA+ÇÇB			
DeepLabV3+	GD	OD	AD	F1 skor	GD	OD	AD	F ₁ Skor
ResNet-50	96.86	88.99	78.53	84.94	97.28	90.00	80.66	86.43
Resnet-18	96.19	81.39	73.17	78.57	96.8	81.11	75.39	82.56
Xception	96.88	91.28	79.31	83.24	97.57	92.86	82.82	86.46
MobileNetv2	95.82	79.88	71.27	77.63	96.37	80.40	73.40	82.53

055 test görüntüsünde en yüksek değerleri DeepLabv3+Xception-ÇÇB modeli ile elde edilmiştir. Genel doğruluk %97.57, Ortalama doğruluk %92.86, Ağırlıklı doğruluk %82.82 ve F1 skoru %86.46 olarak elde edilmiştir. Tek başına kullanılan DÖ modellerinin tahmin doğrulukları ile önerilen yaklaşımın sınıflandırma sonuçları karşılaştırılmıştır. Bu karşılaştırmalarda farklı doğruluk ölçütlerinde yaklaşık %3'ten daha fazlaya varan artışla doğruluk değerlerinde iyileştirme sağladığı gözlemlenmiştir.

ESA ve ESA-ÇÇB modellerinin sonuçlarının bar grafikleri, önerilen yaklaşımın model bazında sağladığı iyileştirmeler göstermektedir (Şekil 3.26 ve Şekil 3.27). Bu şekillerde ifade edilen modeller DeepLabV3+ mimarisi ile birlikte kullanılmıştır.



Şekil 3.26 : DeeplabV3+ mimarisi ile WHUBED veri seti 003 test görüntüsü sonuçları.



Şekil 3.27 : DeeplabV3+ mimarisi ile WHUBED veri seti 055 test görüntüsü sonuçlar

4. TARTIŞMA

Arazi örtüsü haritası ölçeği düşünüldüğünde, piksel tabanlı derin öğrenme yaklaşımı uygulandıktan sonra kartografik genelleştirme faydalı olacaktır. Nitekim ESA tabanlı modellerin uygulanmasıyla tuz biber etkisi görülmektedir. Arazi örtüsü sınıflandırma sistemi (LCCS), özellikle çok küçük nesneler için bazı genelleştirme gereksinimlerine sahiptir. Sentinel veri setindeki deneylerde genellikle gemiler ve limanlar sınıflandırma sonucunda hata sebeplerindendir. Örneğin, gemiler çalışılan bu ölçekte bir nesne olarak kabul edilemeyecek kadar küçük oldukları için referans verisinde su yapıları sınıfı olarak kabul edilmektedir. Referans verilerinde, çok küçük yeşil alanlar, örneğin denizdeki gemiler, komşu geniş alan sınıfına dâhil edilmiştir (Şekil 3.3 ve 3.4). Bu, Sentinel veri setindeki sınıf kesinlik değerlerindeki (Şekil 3.9 ve Şekil 3.10) düşüşün bir nedenidir. Sentinel veri setinde iki farklı test alanında, 5 ve 7 banttan oluşan farklı boyutta veri setleri kullanılmıştır. ESA (U-net)–ÇÇB modelinin beş bantlı veri seti ile daha iyi bir sınıflandırmaya sahip olduğu, İstanbul'da genel doğruluk oranı %97.31 ve F1 skoru %96.06 olduğu bulunmuştur (Çizelge 3.1). Kocaeli test alanında en yüksek değerler ESA (SegNet)–ÇÇB modeli için, genel doğruluk oranı %98.16 ve F1 skoru %92.54 ile yedi bantlı veri seti için bulunmuştur (Çizelge 3.8).

Sentinel veri setindeki deneylerde, ESA-ÇÇB modeli hem beş, hem de yedi-bantlı veri setleri için uygun olduğu gösterilmiştir. Her deney için, önerilen ESA-ÇÇB modelinin tek başına ESA modellerinin kullanımından daha iyi sonuçlara sahip olduğu ortaya çıkmıştır. Deneylerde görüntüdeki gürültü oranı arttıkça, ESA-ÇÇB modeli kullanılarak sınıflandırmadaki iyileştirme miktarı arttığı gözlenmiştir. Ek olarak, Sentinel veri seti için McNemar testi, bu farklı modellerin karşılaştırılmasının bilimsel açıdan anlamlı (significant) olduğunu göstermiştir (Çizelge 3.9).

İkinci deneyde kullanılan Zurich Summer veri seti, sekiz sınıfın birbirinden oldukça farklı ağırlıklarına sahiptir. Bu nedenle, dengesiz (imbalanced) bir veri seti kullanımı AKAÖ haritalamasında performans sonuçlarını etkilemiştir. Bu nedenle, veri setlerindeki en düşük ağırlık sınıfları olan yüzme havuzları ve çıplak arazi sınıfları, test görüntülerinde ESA uygulamalarında segmentlere ayrılamamıştır. Bu durum

özellikle ortalama doğruluk ölçüt değerlerini etkilemiştir (Çizelge 3.10 ve Çizelge 3.11). Genel doğruluk ölçütünde, önerilen yaklaşım Segnet-ÇÇB modeli 128×128 girdi boyutu ile en yüksek genel doğruluk %92.03'tür. Aynı veri setinde yapılan literatürdeki diğer çalışmalardan (Tuia ve diğ, 2018; Zhu ve Lu, 2020; Cui ve diğ, 2017; Hua ve diğ, 2021 ve Djerriri ve diğ, 2017) daha yüksek bir performans değeri elde edilmiştir. Aynı zamanda F1 skoru ölçütünde önerilen yaklaşım Segnet-ÇÇB 32×32 girdi boyutu ile %84.17 sonucuna ulaşmıştır. Aynı veri setinde literatürde elde edilen F1 skorlarından (Hua ve diğ, 2021 ve Djerriri ve diğ, 2017) daha yüksek bir performans elde edilmiştir.

Üçüncü deneyde WHUBED veri setinde de çalışma kapsamında önerilen modelin verimliliği test edilmiştir. 003 test görüntüsü için GD, AD VE F₁ skor ölçütlerinde en yüksek performans DeepLabv3+Xception modeli ile elde edilmiştir. OD metriğinde ise, DeepLabv3+ResNet50 modeli en yüksek değeri vermiştir (Çizelge 3.15). 055 test görüntüsüyle elde edilen sonuçlarda, DeepLabV3+Xception modeli GD, OD, AD VE F1 skor performans değerlendirmelerinde en yüksek sonucu veren algoritma olmuştur (Çizelge 3.16). Uygulamada kullanılan ağ modelleri düşünüldüğünde bu iki DÖ modelinin böyle bir veri seti için (imbalanced ve az görüntüden oluşan) bu sonuçları üretmesi beklenmektedir. Xception mimarisi, bir önceki derin öğrenme mimarilerinin versiyonların iyileştirilmesi ve geliştirilmesiyle elde edilen bir mimaridir.

WHUBED veri seti iki sınıftan oluşan (bina ve bina olmayan) Zurich summer veri seti gibi dengesiz (imbalanced) bir veri seti olmasına rağmen, özellikle F1 skoru değerlerinde önerilen model (ESA-ÇÇB), ESA modelleri sonuçlarına göre anlamlı artış göstermiştir. Bu veri seti iki sınıflı ve DÖ ile semantik etiketlemeye dayalı şekilde seçilen farklı ESA ağları ile sınıflandırılmıştır. Bu sayede önerilen modelin ilk iki uygulamada kullanılan DÖ modellerine özgü şekilde değil, farklı ESA mimarilerinde de sınıflandırma doğruluğunda üstünlük gösterdiği ortaya konmuştur. WHUBED veri setinde sınıflandırması hedeflenen tek bir arazi kullanımı sınıfı mevcuttur. Ancak bina olmayan bölgelerde aslında birçok AKAÖ sınıfı yer almaktadır. Bu sayede bina sınıfı, sınıflandırmada birçok başka sınıftan (yol, tarım arazisi, boş alan vb.) ayırt edilmiş vaziyettedir.

Önerilen yaklaşım, temel DÖ mimarilerinin sonuçlarını iyileştirmektedir. Bu iyileştirme daha çok, DÖ modelinin tespit ettiği sınıfın sınırlarını daha iyi belirlemek şeklindedir. Yani DÖ tahminin bulamadığı sınıfı, önerilen yaklaşımın bulması pek

mümkün olamamaktadır. Örneğin Zurich veri setinin dengesiz olması sebebiyle, yüzme havuzu oldukça küçük ağırlıktadır. DÖ modelleri tahmin değerlerinde test görüntüsünde yüzme havuzunu tahmin haritasında bulamadığı sürece, o sınıfta iyileştirme yapmak mümkün olamayacaktır. Oysa şeklen doğru bulamadığı, yer gerçekliğiyle alan olarak tam örtüşme (IoU ölçütü) sağlanamamış DÖ tahmin sonuçlarını, çalışma kapsamında önerilen yaklaşım, birçok değerlendirme ölçütü açısından iyileştirme sağladığı gözlenmiştir. Bu manada, önerilen yaklaşım nesneye dayalı filtreleme yaparak, DÖ tahmin değerlerini daha isabetli şekilde modifiye etmektedir. Bu da DÖ modelleriyle sınıflandırmanın bir sonucu olan tuz-biber etkisini azaltmaya, sonuç görüntülerindeki gürültüyü azaltmaya olanak sağlamaktadır.

Önerilen yaklaşım, dengeli veri setinde (Sentinel) farklı ölçütlerde, benzer anlamlı artışı göstermektedir. Diğer yandan, dengesiz veri setinde genel doğrulukları belli oranda bir artış sağlasa da, önemli derecede iyileştirmeyi F1 skoru metriğinde yapmaktadır. Aynı zamanda IoU performanslarını da artırdığı gözlenmiştir. AÖAK haritaları üretim uygulamalarında, genel doğruluk kriteri her zaman yeterli ölçüt olamamaktadır. Bu nedenle, uygulamaların performanslarının değerlendirilmesi için, diğer ölçütlerle de test etmek önem arz etmektedir. Önerilen yaklaşım özellikle duyarlılık metriğinde, tek başına DÖ modeli kullanımıyla karşılaştırıldığında önemli bir artış sağlamaktadır (Şekil 3.9 ve Şekil 3.10). Bu da çalışma kapsamındaki son ürün olan tematik haritaların kullanım amacına uygun önemli bir gelişmedir. Bilgisayarlı görü alanında duyarlılık diye geçen ölçüt, atanan sınıfın ne kadar doğru olduğunun ölçütüdür. Uzaktan algılama uygulamalarında kullanıcı doğruluğu olarak karşımıza çıkan bu ölçüt, AKAÖ haritalarını kullanacak tüzel ve özel kişiler için önemli bir yarar sağlayacaktır. Çevresel izleme programlarında sınıflandırmaları otomatikleştirme ihtiyacı, periyodik üretimle bağlantılıdır. Ancak üretilen tematik haritaların sağlanması gereken doğruluk ölçütü de (özellikle genel doğruluk ölçütü), hızlı ve otomatik üretim kadar önemlidir. Bu nedenle, çalışmanın amacı olarak, sağlam, etkili ve hızlı bir modelle AKAÖ haritaları ile kartografik bilgi çıkarımının sağlanması, çalışma kapsamındaki farklı uygulamalarla gerçekleştirilmiştir. Önerilen yaklaşım, farklı veri setlerinde ve farklı mekânsal çözünürlüklü girdi görüntülerinde isabetli sonuçlar vermektedir. Aynı zamanda, farklı seviyelerdeki AKAÖ ve arazi kullanımı için de uygunluğu bu çalışmada gösterilmiştir. Kullanılan veri setinin görüntülerinin sahip olduğu bant sayısı üç-bant veya daha fazla bant ile mümkün olmaktadır. Bu sayede,

bu çalışmada kullanılan yöntemler, veri olarak kullanılan görüntülere ek bantların eklenmesiyle, bilgi çıkarımı hedeflenen sınıflar için farklı kombinasyonlarla kullanılabilir. Bu da, çalışmadaki yöntem ile uzaktan algılama alanındaki uzmanlık bilgisinin, önerilen yaklaşımda derin öğrenme uygulamalarıyla bir arada sentezlenebileceği anlamını taşımaktadır.

Evrişimli sinir ağlarının arazi örtüsü haritalaması için literatürdeki birçok çalışmada geniş olmayan (kıyasla küçük) alanlara (Zurich Summer ve WHUBED veri setleri gibi) odaklanmıştır. Bununla birlikte, geniş alanlarda geleneksel ESA yöntemlerini kullanmak, daha düşük doğruluklu harita sonuçları üretebilmektedir (Martins ve diğ, 2020). Tez kapsamındaki uygulamalarda elde edilen bulgular, nesne tabanlı yaklaşımlarla ESA modellerini birleştirerek sınıflandırma sonuçlarının iyileştirilebileceğini ortaya koymuştur. Çalışmadaki uygulamaların bulguları benzer çalışmalarla uyumludur (Martins ve diğ, 2020; Du ve diğ, 2020).

5. SONUÇ VE ÖNERİLER

Tez kapsamında farklı detay seviyelerinde derin öğrenme teknikleri kullanılarak AKAÖ haritaları üretilmiştir. Ayrıca DÖ modeli kullanılarak üretilmiş tahmin sonuçları üzerinde, nesne tabanlı bir yaklaşımla sınıflandırmayı iyileştirme aşaması da önerilen yaklaşımda mevcuttur. Tüm uygulamalar, literatürdeki DÖ mimarileri ile sınıflandırılarak sonuçlar üretilmiş, aynı zamanda önerilen yaklaşım (ESA-ÇÇB) ile de üretilen sonuçlarla karşılaştırılmıştır. Birçok değerlendirme metriğinde karşılaştırılan bu sonuçlara göre, önerilen yaklaşımın üstünlüğü çalışmada gösterilmiştir. Önerilen yaklaşım olan ESA-ÇÇB'nin yöntemi veriye dayalıdır ve aynı mekânsal çözünürlükteki farklı bölgesel görüntülere uyarlanabilir. Eğitim ve test alanının boyutları ve özellikleri, uygulamalar kısmında belirtildiği gibi kullanılan DÖ model gereksinimlerine göre düzenlenebilir. Sentinel veri seti deneyinde bu amaçla, eğitim alanı alanından farklı bir şehirde bir test alanı seçilmiştir. Bu test alanında da, önerilen yaklaşımla elde edilen sonuçların tutarlı ve kullanıma uygun olduğu gösterilmiştir. Ayrıca Sentinel-2 ve Zurich Summer veri setindeki deneylerde her iki ESA model sınıflandırıcı (U-net, SegNet) için de üç farklı görüntü parçacığı (32, 64, 128) boyutu ile deneyler yapılmıştır. Zurich veri setinde literatürde kullanılan diğer modellerle karşılaştırma yapılmıştır. WHUBED açık veri setinde diğer açık veri seti olan Zurich Summer veri setindeki uygulamadan farklı DÖ mimariler seçilmiş, önerilen yaklaşımın bu farklı ağ yapıları kullanarak da değerlendirme ölçütlerinde iyileştirme sağladığı gösterilmek istenmiştir.

Sentinel, Zurich Summer ve WHUBED veri setleri için semantik segmentasyon için ESA-ÇÇB modeli ve diğer güncel ESA modelleri kullanılmıştır. Her veri seti kullanımında sonuç ürün olarak arazi kullanımı veya AKAÖ tematik haritaları üretilmiştir. Deneylerde önerilen yöntemin, diğer sonuçlarla karşılaştırılması literatürde yaygın kullanılan doğruluk değerlendirme ölçütleri ile yapılmıştır.

Sonuç olarak, tez kapsamındaki uygulamalar ile farklı semantik seviyelerde AKAÖ üretiminde önerilen yaklaşımın kullanımının tek başına uygulanan ESA modellerinden daha iyi bir sınıflandırma yeteneğine sahip olduğu gözlenmiştir. Geniş ve geniş

olmayan alanlarda eğitilen modellerde önerilen modelin uygulanabilirliği kanıtlanmıştır. Dengeli ve dengesiz sınıf dağılımına sahip veri setinde önerilen yaklaşımın kullanımının tek sınıf ve çok sınıf için semantik segmentasyon için uygulanabilirliği gösterilmiştir.

Yer gözlem uygulamalarında, AKAÖ haritaları oldukça önemli bir rol oynamaktadır. Bu alanda otomatik sınıflandırma sistemleri ve harita doğruluklarında iyileştirme çalışmaları büyük potansiyele sahip görevlerdir. Gelecekteki çalışmalarda, bu çalışma kapsamındaki uygulamalar; girdi verisine doku (texture) bilgisi ve sayısal yükseklik modeli (SYM) katmanını dâhil olmak üzere farklı bant eklemeleriyle gerçekleştirilebilir. Ek olarak, 128x128 ‘den daha büyük görüntü parçacığı boyutlarında deneyler gerçekleştirilip, sınıflandırma doğruluğuna etkileri araştırılabilir. Aynı zamanda, önerilen yaklaşım çalışmalarının devamında diğer açık veri setlerinde uygulanması ve kullanılacak doğruluk ölçütleriyle sonuçlardaki iyileştirmenin sağlanması yardımıyla farklı AÖAK haritaları için de pekiştirilebilir.

KAYNAKLAR

- Abdollahi, A., Pradhan, B., & Alamri, A. M.** (2020). An ensemble architecture of deep convolutional Segnet and Unet networks for building semantic segmentation from high-resolution aerial images. *Geocarto International*, 1-16.
- Alhassan, V., Henry, C., Ramanna, S., & Storie, C.** (2020). A deep learning framework for land-use/land-cover mapping and analysis using multispectral satellite imagery. *Neural Computing and Applications*, 32(12), 8529-8544.
- Atik, M. E., & Duran, Z.** (2020, October). Deep Learning-Based 3D Face Recognition Using Derived Features from Point Cloud. In *The Proceedings of the Third International Conference on Smart City Applications* (pp. 797-808). Springer, Cham.
- Atik, S. O. ve İpbüker, C.,** (2020a), *Instance segmentation of crowd detection in the camera images. In Proceedings of ACRS 2020 - 41st Asian Conference on Remote Sensing*, Deqing, China, November 9-11, 2020.
- Atik, S. O., & İpbüker, C.** (2020b). Multi-Label Classification Application for Environmental Monitoring Applications with Deep Learning Approaches, *20th International Symposium on Environmental Pollution and its Impact on Life in the Mediterranean Region*, 26-27 Ekim 2020, Atina, Yunanistan
- Atik, S. O., & İpbüker, C.** (2020c). Building Extraction with VHR Remote Sensing Imagery through Deep Learning, *20th International Symposium on Environmental Pollution and its Impact on Life in the Mediterranean Region*, 26-27 Ekim 2020
- Atik, S. O., & İpbüker, C.** (2021a). Integrating Convolutional Neural Network and Multiresolution Segmentation for Land Cover and Land Use Mapping Using Satellite Imagery. *Applied Sciences*, 11(12), 5551.
- Atik, S. O., & İpbüker, C.** (2021b). Uydu Görüntülerinden Örnek Segmentasyonu ile Gemi Tespiti, *18. Türkiye Harita Bilimsel ve Teknik Kurultayı*, Ankara, 26-29 Mayıs 2021.
- Audebert, N., Le Saux, B., & Lefèvre, S.** (2016). Semantic segmentation of earth observation data using multimodal and multi-scale deep networks. In *Asian conference on computer vision* (pp. 180-196). Springer, Cham.
- Audebert, N., Le Saux, B., & Lefèvre, S.** (2018). Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20-32.

- Baatz, M.** (2000). Multi resolution segmentation: an optimum approach for high quality multi scale image segmentation. In *Beutrage zum AGIT-Symposium. Salzburg, Heidelberg, 2000* (pp. 12-23).
- Badrinarayanan, V., Kendall, A., & Cipolla, R.** (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- Baydilli, Y. Y.** (2021). Polen Taşıyan Bal Arılarının MobileNetV2 Mimarisi ile Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (21), 527-533.
- Bi, Q., Qin, K., Zhang, H., Zhang, Y., Li, Z., & Xu, K.** (2019). A multi-scale filtering building index for building extraction in very high-resolution satellite imagery. *Remote Sensing*, 11(5), 482.
- Blaschke, T.** (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16.
- Bronge, L. B., & Näslund-Landenmark, B.** (2002). Wetland classification for Swedish CORINE Land Cover adopting a semi-automatic interactive approach. *Canadian journal of remote sensing*, 28(2), 139-155.
- Brown, N., Gerard, F., & Fuller, R.** (2002). Mapping of land use classes within the CORINE land cover map of Great Britain. *The Cartographic Journal*, 39(1), 5-14.
- Chen, G., Li, C., Wei, W., Jing, W., Woźniak, M., Blažauskas, T., & Damaševičius, R.** (2019). Fully convolutional neural network with augmented atrous spatial pyramid pool and fully connected fusion path for high resolution remote sensing image segmentation. *Applied Sciences*, 9(9), 1816.
- Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L.** (2017b). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE transactions on pattern analysis and machine intelligence*, 40(4), 834-848.
- Chen, L. C., Papandreou, G., Schroff, F., & Adam, H.** (2017a). Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*.
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H.** (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 801-818).
- Chollet, F.** (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- Clinton, N., Holt, A., Scarborough, J., Yan, L. I., & Gong, P.** (2010). Accuracy assessment measures for object-based image segmentation goodness. *Photogramm. Eng. Remote Sens*, 76(3), 289-299.
- Cui, Y., Chapel, L., & Lefevre, S.** (2017). Scalable bag of subpaths kernel for learning on hierarchical image representations and multi-source remote sensing data classification. *Remote sensing*, 9(3), 196.

- Demir, I., Koperski, K., Lindenbaum, D., Pang, G., Huang, J., Basu, S., ... & Raskar, R.** (2018). Deepglobe 2018: A challenge to parse the earth through satellite images. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 172-181).
- Deng, J., Ding, N., Jia, Y., Frome, A., Murphy, K., Bengio, S., ... & Adam, H.** (2014). Large-scale object classification using label relation graphs. In *European conference on computer vision* (pp. 48-64). Springer, Cham.
- Ding, H., Liu, K., Chen, X., Xiong, L., Tang, G., Qiu, F., & Strobl, J.** (2020). Optimized segmentation based on the weighted aggregation method for loess bank gully mapping. *Remote Sensing*, 12(5), 793.
- Djerriri, K., & Karoui, M.S.** (2017). Classification of quickbird imagery over urban area using convolutional neural network. In *2017 Joint Urban Remote Sensing Event (JURSE)*, pp. 1-4, IEEE.
- Donmez, S.O.; Ipbuker, C.** (2018). Investigation on Agent Based Models for Image Classification of Land Use and Land Cover Maps. In *Proceedings of the 39th Asian Conference on Remote Sensing (ACRS): Remote Sensing Enabling Prosperity*, Kuala Lumpur, Malaysia, 15–19 October 2018; pp. 2005–2008.
- Du, S.; Du, S.; Liu, B.; Zhang, X.** (2020). Incorporating DeepLabv3+ and object-based image analysis for semantic segmentation of very high resolution remote sensing images. *Int. J. Digit. Earth* 14, 1–22.
- Eppel, S., & Aspuru-Guzik, A.** (2019). Generator evaluator-selector net for panoptic image segmentation and splitting unfamiliar objects into parts. *arXiv preprint arXiv:1908.09108*.
- Foody, G. M.** (2004). Thematic map comparison. *Photogrammetric Engineering & Remote Sensing*, 70(5), 627-633.
- Ghorbanzadeh, O., Tiede, D., Wendt, L., Sudmanns, M., & Lang, S.** (2021). Transferable instance segmentation of dwellings in a refugee camp-integrating CNN and OBIA. *European Journal of Remote Sensing*, 54(sup1), 127-140.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). Deep learning. Cambridge, MA.: MIT press.
- Gujrathi, A., Yang, C., Rottensteiner, F., Buddhiraju, K. M., & Heipke, C.** (2020). Improving the classification of Land use Objects using Dense Connectivity of Convolutional Neural Networks. *ISPRS Archives of Phot., Rem. Sens. and Spat. Info. Sc.* volume 43, B2, 43(B2), 667-673.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R.** (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- He, K., Zhang, X., Ren, S., & Sun, J.** (2015). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Henry, C. J., Storie, C. D., Palaniappan, M., Alhassan, V., Swamy, M., Aleshinloye, D., ... & Kim, D.** (2019). Automated LULC map

production using deep neural networks. *International Journal of Remote Sensing*, 40(11), 4416-4440.

- Heryadi, Y., & Miranda, E.** (2019, April). Land cover classification based on Sentinel-2 satellite imagery using Convolutional Neural Network model: A case study in Semarang Area, Indonesia. In *Asian Conference on Intelligent Information and Database Systems* (pp. 191-206). Springer, Cham.
- Hossain, M. D., & Chen, D.** (2019). Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 115-134.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H.** (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Hua, Y., Marcos, D., Mou, L., Zhu, X. X., & Tuia, D.** (2021) Semantic Segmentation of Remote Sensing Images With Sparse Annotations. *IEEE Geoscience and Remote Sensing Letters*, 1-5.
- Hua, Y., Mou, L., & Zhu, X. X.** (2019). Recurrently exploring class-wise attention in a hybrid convolutional and bidirectional LSTM network for multi-label aerial image classification. *ISPRS journal of photogrammetry and remote sensing*, 149, 188-199.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q.** (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Kampffmeyer, M., Salberg, A. B., & Jenssen, R.** (2016). Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 1-9).
- Kavzoglu, T., & Tonbul, H.** (2018). An experimental comparison of multi-resolution segmentation, SLIC and K-means clustering for object-based classification of VHR imagery. *International journal of remote sensing*, 39(18), 6020-6036.
- Kemker, R., Salvaggio, C., & Kanan, C.** (2018). Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning. *ISPRS journal of photogrammetry and remote sensing*, 145, 60-77.
- Lang, S., Hay, G. J., Baraldi, A., Tiede, D., & Blaschke, T.** (2019). Geobia achievements and spatial opportunities in the era of big earth observation data. *ISPRS International Journal of Geo-Information*, 8(11), 474.

- Lee, S. H., & Baik, J. J.** (2011). Evaluation of the vegetated urban canopy model (VUCM) and its impacts on urban boundary layer simulation. *Asia-Pacific Journal of Atmospheric Sciences*, 47(2), 151-165.
- Leiva-Murillo, J. M., Gómez-Chova, L., & Camps-Valls, G.** (2012). Multitask remote sensing data classification. *IEEE transactions on geoscience and remote sensing*, 51(1), 151-161.
- Li, E., Samat, A., Liu, W., Lin, C., & Bai, X.** (2019). High-resolution imagery classification based on different levels of information. *Remote Sensing*, 11(24), 2916.
- Li, W., He, C., Fang, J., Zheng, J., Fu, H., & Yu, L.** (2019). Semantic segmentation-based building footprint extraction using very high-resolution satellite images and multi-source GIS data. *Remote Sensing*, 11(4), 403.
- Liu, T., Abd-Elrahman, A., Morton, J., & Wilhelm, V. L.** (2018). Comparing fully convolutional networks, random forest, support vector machine, and patch-based deep convolutional neural networks for object-based wetland mapping using images from small unmanned aircraft system. *GIScience & remote sensing*, 55(2), 243-264.
- Liu, T., Yang, L., & Lunga, D.** (2021). Change detection using deep learning approach with object-based image analysis. *Remote Sensing of Environment*, 256, 112308.
- Liu, Y., Fan, B., Wang, L., Bai, J., Xiang, S., & Pan, C.** (2018). Semantic labeling in very high resolution images via a self-cascaded convolutional neural network. *ISPRS journal of photogrammetry and remote sensing*, 145, 78-95.
- Long, J., Shelhamer, E., & Darrell, T.** (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- Loveland, T., Merchant, J., Brown, J., & Ohlen, D.** (1991). Development of a land-cover characteristics database for the conterminous U. S. *Photogrammetric engineering and remote sensing*, 57(11), 1453-1463.
- Lucieer, A., & Stein, A.** (2002). Existential uncertainty of spatial objects segmented from satellite sensor imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11), 2518-2521.
- Lv, Q., Dou, Y., Niu, X., Xu, J., Xu, J., & Xia, F.** (2015). Urban land use and land cover classification using remotely sensed SAR data through deep belief networks. *Journal of Sensors*, 2015.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A.** (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.
- Marcu, A., & Leordeanu, M.** (2016). Dual local-global contextual pathways for recognition in aerial imagery. *arXiv preprint arXiv:1605.05462*.
- Marmanis, D., Wegner, J. D., Galliani, S., Schindler, K., Datcu, M., & Stilla, U.** (2016). Semantic segmentation of aerial images with an ensemble of

CNSS. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2016, 3, 473-480.

- Martins, V. S., Kaleita, A. L., Gelder, B. K., da Silveira, H. L., & Abe, C. A.** (2020). Exploring multiscale object-based convolutional neural network (multi-OCNN) for remote sensing image classification at high spatial resolution. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168, 56-73.
- McNemar, Q.** (1947). Note on the sampling error of the difference between correlated proportions or percentages. *Psychometrika*, 12(2), 153-157.
- Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., & Terzopoulos, D.** (2021). Image segmentation using deep learning: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Neves, A. K., Körting, T. S., Fonseca, L. M. G., Girolamo Neto, C. D., Wittich, D., Costa, G. A. O. P., & Heipke, C.** (2020). Semantic segmentation of brazilian savanna vegetation using high spatial resolution satellite data and u-net. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*; volume 5, 3, 5(3), 505-511.
- Noh, H., Hong, S., & Han, B.** (2015). Learning deconvolution network for semantic segmentation. In *Proceedings of the IEEE international conference on computer vision* (pp. 1520-1528).
- Paisitkriangkrai, S., Sherrah, J., Janney, P., & Hengel, V. D.** (2015). Effective semantic pixel labelling with convolutional networks and conditional random fields. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 36-43).
- Pan, Z., Xu, J., Guo, Y., Hu, Y., & Wang, G.** (2020). Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net. *Remote Sensing*, 12(10), 1574.
- Panboonyuen, T., Jitkajornwanich, K., Lawawirojwong, S., Srestasathien, P., & Vateekul, P.** (2019). Semantic segmentation on remotely sensed images using an enhanced global convolutional network with channel attention and domain specific transfer learning. *Remote Sensing*, 11(1), 83.
- Papadomanolaki, M., Vakalopoulou, M., & Karantzas, K.** (2019). A novel object-based deep learning framework for semantic segmentation of very high-resolution remote sensing data: Comparison with convolutional and fully convolutional networks. *Remote Sensing*, 11(6), 684.
- Pearson, R. L., & Miller, L. D.** (1972). Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie. *Remote sensing of environment*, VIII, 1355.
- Pekkarinen, A., Reithmaier, L., & Strobl, P.** (2009). Pan-European forest/non-forest mapping with Landsat ETM+ and CORINE Land Cover 2000 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(2), 171-183.

- Qin, Y., Wu, Y., Li, B., Gao, S., Liu, M., & Zhan, Y.** (2019). Semantic segmentation of building roof in dense urban environment with deep convolutional neural network: A case study using GF2 VHR imagery in China. *Sensors*, 19(5), 1164.
- Richardson, A. J., & Wiegand, C. L.** (1977). Distinguishing vegetation from soil background information. *Photogrammetric engineering and remote sensing*, 43(12), 1541-1552.
- Roni, R., & Jia, P.** (2020). An optimal population modeling approach using geographically weighted regression based on high-resolution remote sensing data: A case study in Dhaka City, Bangladesh. *Remote Sensing*, 12(7), 1184.
- Ronneberger, O., Fischer, P., & Brox, T.** (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W.** (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA special publication*, 351(1974), 309.
- Rousset, G., Despinoy, M., Schindler, K., & Mangeas, M.** (2021). Assessment of Deep Learning Techniques for Land Use Land Cover Classification in Southern New Caledonia. *Remote Sensing*, 13(12), 2257.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C.** (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Schöpfer, E., Lang, S., & Strobl, J.** (2010). Segmentation and object-based image analysis. In *Remote sensing of urban and suburban areas* (pp. 181-192). Springer, Dordrecht.
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sumbul, G., Charfuelan, M., Demir, B., & Markl, V.** (2019, July). Bigearthnet: A large-scale benchmark archive for remote sensing image understanding. In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 5901-5904). IEEE.
- Sunar, F., Özkan, C., & Osmanoğlu, B.** (2018). *Uzaktan Algılama* (4. bs). Anadolu Üniversitesi Yayını, Eskişehir: Anadolu Üniversitesi Basımevi.
- Tempfli, K., Kerle, N., Huurneman, G. C., & Janssen, L. L.** (2009). *Principles of remote sensing: an introductory textbook* (4. bs). International Institute for Geo-Information Science and Earth Observation, Educational textbook series: 2. Enschede: ITC.
- Tetteh, G. O., Gocht, A., Schwieder, M., Erasmı, S., & Conrad, C.** (2020). Unsupervised Parameterization for Optimal Segmentation of Agricultural Parcels from Satellite Images in Different Agricultural Landscapes. *Remote Sensing*, 12(18), 3096.

- Tian, J., & Chen, D. M.** (2007). Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing*, 28(20), 4625-4644.
- Tucker, C. J.** (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
- Tuia, D., Volpi, M., & Moser, G.** (2018). Decision fusion with multiple spatial supports by conditional random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 56(6), 3277-3289.
- URL-1** < <https://sdgs.un.org/goals>>, erişim tarihi 06.10.2021.
- URL-2** Copernicus-CORINE Land Cover. Available online: <https://land.copernicus.eu/pan-european/corine-land-cover>, erişim tarihi 25.12.2020.
- URL-3** < <https://scihub.copernicus.eu/> >, erişim tarihi 21.12.2020.
- URL-4** <<https://earthexplorer.usgs.gov/>>, erişim tarihi 21.12.2020.
- URL-5** < https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook> ESA Sentinel-2 User Handbook, 2015: User Handbook. ESA Standard Document, erişim tarihi 20.09.2021.
- Vali, A., Comai, S., & Matteucci, M.** (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15), 2495.
- Volpi, M., & Ferrari, V.** (2015). Semantic segmentation of urban scenes by learning local class interactions. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (pp. 1-9).
- Volpi, M., & Tuia, D.** (2016). Dense semantic labeling of subdecimeter resolution images with convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 881-893.
- Wang, H., Wang, Y., Zhang, Q., Xiang, S., & Pan, C.** (2017). Gated convolutional neural network for semantic segmentation in high-resolution images. *Remote Sensing*, 9(5), 446.
- Wang, M.** (2008). A multiresolution remotely sensed image segmentation method combining rainfalling watershed algorithm and fast region merging. *Int. Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 1213-1217.
- Wang, N., Chen, F., Yu, B., & Qin, Y.** (2020). Segmentation of large-scale remotely sensed images on a Spark platform: A strategy for handling massive image tiles with the MapReduce model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 137-147.
- Wang, S., Chen, W., Xie, S. M., Azzari, G., & Lobell, D. B.** (2020). Weakly supervised deep learning for segmentation of remote sensing imagery. *Remote Sensing*, 12(2), 207.
- Winter, S.** (2000). Location similarity of regions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 55(3), 189-200.

- Wurm, M., Stark, T., Zhu, X. X., Weigand, M., & Taubenböck, H.** (2019). Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks. *ISPRS journal of photogrammetry and remote sensing*, 150, 59-69.
- Yang, C., Rottensteiner, F., & Heipke, C.** (2018). Classification of land cover and land use based on convolutional neural networks. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 4 (2018), Nr. 3, 4(3), 251-258.
- Yang, C., Rottensteiner, F., & Heipke, C.** (2020b). Exploring semantic relationships for hierarchical land use classification based on convolutional neural networks. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*; volume 5, 2, 5(2), 599-607.
- Yang, C., Rottensteiner, F., & Heipke, C.** (2021). A hierarchical deep learning framework for the consistent classification of land use objects in geospatial databases. *ISPRS Journal of Photogrammetry and Remote Sensing*, 177, 38-56.
- Yao, X., Yang, H., Wu, Y., Wu, P., Wang, B., Zhou, X., & Wang, S.** (2019). Land use classification of the deep convolutional neural network method reducing the loss of spatial features. *Sensors*, 19(12), 2792.
- Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J., & Atkinson, P. M.** (2018). An object-based convolutional neural network (OCNN) for urban land use classification. *Remote sensing of environment*, 216, 57-70.
- Zhang, Y., & Chi, M.** (2020). Mask-R-FCN: A deep fusion network for semantic segmentation. *IEEE Access*, 8, 155753-155765.
- Zhao, W., Du, S., Wang, Q., & Emery, W. J.** (2017). Contextually guided very-high-resolution imagery classification with semantic segments. *ISPRS journal of photogrammetry and remote sensing*, 132, 48-60.
- Zhu, M. & Lu, J.** (2020). An Effective Attention-Guided Feature Fusion Network for Segmentation of Remote Sensing Imagery. In *2020 12th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)*, pp. 269-274, IEEE.



ÖZGEÇMİŞ

Ad-Soyad : Şaziye Özge ATİK

ÖĞRENİM DURUMU:

- **Lisans** : 2012, İTÜ, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü
- **Yüksek Lisans** : 2015, İTÜ, FBE, Geomatik Mühendisliği ABD, Geomatik Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2012-2013 yılları arasında İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Uygulama ve Araştırma Merkezi (UHUZAM)'da çalıştı.
- 2013-2020 yılları arasında İTÜ Geomatik Mühendisliği Bölümünde araştırma görevlisi olarak çalıştı.
- 2018 yılında Twente Üniversitesi (Hollanda) ITC Earth Observation Science (EOS) departmanında tez araştırmaları için akademik ziyaretçi olarak bulundu.
- 2020 yılında Gebze Teknik Üniversitesi Harita Mühendisliği Bölümünde öğretim görevlisi olarak çalışmaya başladı ve aynı yerde görevine halen devam etmektedir.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Atik, S. O., & İpbuker, C.** 2021. Integrating Convolutional Neural Network and Multiresolution Segmentation for Land Cover and Land Use Mapping Using Satellite Imagery. *Applied Sciences*, 11(12), 5551.
- **Atik, S. O., & İpbuker, C.** 2021. Uydu Görüntülerinden Örnek Segmentasyonu ile Gemi Tespiti 18. Türkiye Harita Bilimsel ve Teknik Kurultayı, 26-29 Mayıs 2021, Ankara
- **Atik, S. O., & İpbuker, C.** 2020. Building Extraction with VHR Remote Sensing Imagery through Deep Learning, *20th International Symposium on Environmental Pollution and its Impact on Life in the Mediterranean Region*, 26-27 Ekim 2020
- **Atik, S. O., & İpbuker, C.** 2020. Multi-Label Classification Application for Environmental Monitoring Applications with Deep Learning Approaches, *20th*

International Symposium on Environmental Pollution and its Impact on Life in the Mediterranean Region, 26-27 Ekim 2020, Atina, Yunanistan

- **Atik, S. O., & İpbüker, C.** 2018. Investigation on Agent Based Models for Image Classification of Land Use and Land Cover Maps, *The 39th Asian Conference on Remote Sensing (ACRS 2018)*, 15- 19 Ekim 2018, 2005 - 2008. Kuala Lumpur, Malezya

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

Atik, S. O., & İpbüker, C. 2020. Instance Segmentation of Crowd Detection in the Camera Images, *41st Asian Conference on Remote Sensing-ACRS2020*, Deqing, Çin

Atik M.E, **Dönmez Ş. Ö.**, Duran Z, İpbüker C. 2018. Comparison of Automatic Feature Extraction Methods for Building Roof Planes by Using Airborne LIDAR Data and High Resolution Satellite Image, *7th International Conference on Cartography and GIS ICCGIS2018*, 18 -23 Haziran 2018, 1, 857 - 863. Sozopol, Bulgaristan

Atik M.E, **Dönmez Ş. Ö.**, Duran Z, İpbüker C, Ünlüer T. 2018. Estimation of Potential Stream Beds Using Dem: Case Study Kahramanmaraş City, *7th International Conference on Cartography and GIS ICCGIS2018*, 18 - 23 Haziran 2018, 1, 801 - 806. Sozopol, Bulgaristan

Dönmez Ş. Ö., İpbüker C. 2017. Digital Change Detection Methods in Rural-Urban Land Area Monitoring: Karapınar District, Sözlü Sunum, *International Symposium On GIS Applications in Geography Geosciences*, 18 - 21 Ekim 2017. Çanakkale, Türkiye

Dönmez Ş. Ö., Tonbul H. 2017. Monitoring Agricultural Lands with Remote Sensing GIS Technology and Reviewing Smart Approaches in Agriculture: in Turkey - Trakya Region, Mediterranean Scientific Association of Environmental Protection (MESAEP), 04 - 07 Ekim 2017, Roma, İtalya

Dönmez Ş. Ö., Tunç A. 2016. Transformation methods for using combination of remotely sensed data and cadastral maps, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 12- 19 Temmuz 2016, 4, 587 - 589, DOI:10.5194/isprsarchives-XLI-B4-587-2016, Prag, Çekya

Dönmez, Ş. Ö. 2016. Incorporating GIS and Multi Criteria Analysis for Flood Risk Mapping: Edirne Example, *Selçuk International Scientific Conference On Applied Sciences – 2016*, Antalya, Türkiye

Dönmez Ş. Ö., Tonbul H., Akay S. S.. 2015. Detecting Clear – Cut Area Using Remotely Sensed Data in İstanbul – Şile Region, *World Cadastre Summit 20- 25 Nisan 2015*, İstanbul, Türkiye

Dönmez Ş. Ö. 2014. Kıyı-Kenar Uzunluğu İle Orantılı Olarak Kıta Sahaneliği Aidiyeti Belirleme: Karadeniz Örneği, *Karadeniz ve Kafkasya'da Güvenlik ve İş Birliği Paneli*, 31 Mart 2014; ISBN:978-975-409-684-2, 105 - 120. İstanbul, Türkiye