

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**DERİN ÖĞRENME METOTLARI KULLANILARAK SAR (SENTETİK
AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDEN BİNA TESPİTİ**

Recai Alper EMEK

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2022

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**DERİN ÖĞRENME METOTLARI KULLANILARAK SAR (SENTETİK
AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDEN BİNA TESPİTİ**

Recai Alper EMEK

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2022

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME METOTLARI KULLANILARAK SAR (SENTETİK
AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDEN BİNA TESPİTİ**

Recai Alper EMEK

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Bu tez 26/01/2022 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Doç. Dr. Nusret DEMİR (DANIŞMAN)

Prof. Dr. Bekir Taner SAN

Dr. Uğur ACAR

ÖZET

Derin Öğrenme Metotları Kullanılarak SAR (Sentetik Açıklıklı Radar) Görüntülerinden Bina Tespiti

Recai Alper EMEK

**Yüksek Lisans Tezi, Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri
Anabilim Dalı**

Danışman: Doç. Dr. Nusret DEMİR

Ocak 2022; 45 sayfa

SAR (Sentetik Açıklıklı Radar) görüntüleri, objelerin yansıma değerleri yerine saçılma değerleri ile oluşturulduklarından optik görüntülerden farklıdır. Bu durum SAR görüntülerinin geleneksel nesne algılama ve tespit metodolojilerinin uygulanmasını zorlaştırır. Son yıllarda derin öğrenme metotları obje tespiti ve segmentasyon alanlarında sıklıkla kullanılmaktadır. Bu çalışmada SAR ve optik görüntü füzyonundan bina tespiti için U-Net modellerinin potansiyelleri araştırılmıştır. Geliştirilen metot ve U-Net algoritması iki farklı veri seti üzerinde uygulanmıştır. İlk veri seti ‘SpaceNet 6 Multi Sensor All-Weather Mapping’ etkinliği kapsamında sağlanan Sentinel-1 SAR ve Sentinel-2 multispektral uydu görüntüleridir. Görüntüler Hollanda’nın Rotterdam bölgesinde 120 km²’lik alanı kapsamaktadır. Eğitim veri seti 20 adet 900 x 900 piksel boyutlu HV polarize SAR görüntüsü ve optik görüntülerdir. Eğitim sonucu oluşturulan modelde Loss (Kayıp) değeri 0.4 doğruluk ise 81% olarak hesaplanmıştır. İkinci veri seti ise İzmir ilinin bir kısmını kapsamakta olup 2020 Ege Denizi depreminden önce ve sonra olmak üzere 2 adet SAR görüntüsünden oluşmaktadır. U-Net algoritmasında maske olarak kullanılacak görüntü, vektörel formattan elde edilmiştir. İlk veri seti üzerinden üretilen model, ilk ve ikinci veri setleri üzerinde uygulanmış ve sonuçlar tartışılmıştır. 3 farklı test verisi üzerine uygulanan modelin sınıflandırma doğrulukları ile sırasıyla 79%, 65% ve 54% olarak hesaplanmıştır.

ANAHTAR KELİMELER: Bina Tespiti, Derin Öğrenme, Optik Görüntü, SAR, U-Net, Uzaktan Algılama

JÜRİ: Prof. Dr. Bekir Taner SAN

Doç. Dr. Nusret DEMİR

Dr. Uğur ACAR

ABSTRACT

Building Detection from SAR (Synthetic Aperture Radar) Images Using Deep Learning Methods

Recai Alper EMEK

Master Thesis in Remote Sensing And Geographic Information Systems

Department

Supervisor: Assoc. Prof. Dr. Nusret DEMİR

January 2022; 45 pages

SAR images are different from the optical images in terms of image properties with the values of scattering instead of reflectance. This makes SAR images difficult to apply the traditional object detection methodologies. In recent years, deep learning models are frequently used in segmentation and object detection purposes. In this study, we have investigated the potential of U-Net models for building detection from SAR and optical image fusion. The datasets used are Sentinel 1 SAR and Sentinel-2 multispectral images, provided from ‘SpaceNet 6 Multi Sensor All- Weather Mapping’ challenge. These images cover an area of 120 km² in Rotterdam, the Netherlands. As training datasets 20 pieces of 900 by 900 pixel sized HV polarized and optical image patches have been used together. The calculated loss value is 0.4 and the accuracy is 81%. The second dataset covers a part of İzmir province and consists of 2 SAR images, before and after the 2020 Aegean Sea earthquake. The image to be used as a mask in the U-Net algorithm was obtained from vector format. The model produced on the first dataset was applied on the second dataset and the results were discussed. Model has been applied on 3 different test dataset and classification results calculated 79%, 65% and 54% respectively.

KEYWORDS: Building Detection, Deep Learning, Electro Optical Image, Remote Sensing, SAR, U-Net

COMMITTEE: Assoc. Prof. Dr. Nusret DEMİR

Prof. Dr. Bekir Taner SAN

Asst. Prof. Dr. Uğur ACAR

ÖNSÖZ

Yüksek Lisans eğitimim süresince ve tez çalışmamın hayata geçirilmesinde bilgi ve tecrübeleriyle bana yol gösteren, araştırma sürecimin her aşamasında görüş ve yönlendirmeleriyle desteğini ve yardımlarını esirgemeyen danışman hocam Doç. Dr. Nusret DEMİR'e, değerli bilgi ve tecrübelerini benimle paylaşan değerli hocalarım Prof. Dr. Bekir Taner SAN ve Dr. Uğur ACAR hocalarıma sonsuz teşekkürlerimi sunarım.

Lisans eğitimimim sürecinde Uzaktan algılamaya yönelik farkındalık oluşturan ve bu alanda yaptığım çalışmalara ışık tutan, bilgi, tecrübe ve desteğini esirgemeyen değerli hocam Prof. Dr. Fatmagül KILIÇ'a sonsuz teşekkürlerimi sunarım.

Hayatım boyunca beni her alanda destekleyen, aldığım kararlarda her zaman yanımda olan, eğitim hayatım boyunca beni cesaretlendiren ve moral veren, tez çalışmamın her aşamasında beni motive eden sevgili kardeşim Emre EMEK, babam Mehmet EMEK'e ve canım annem Beyhan EMEK'e sonsuz teşekkür ve sevgilerimi sunarım.

Her zaman yanımda olan ve tez çalışmam sürecinde desteğini ve yardımlarını esirgemeyen değerli arkadaşlarım Melisa DAĞLAR, Görkem ACAR, Barış KILIÇ, Deniz Ekin TOKTAŞ ve Tugay BEKDEMİR'e sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	v
SİMGELER VE KISALTMALAR.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
2.1. Uzaktan Algılamada Makine Öğrenimi	4
3. MATERYAL VE METOT	9
3.1. Çalışma Alanları ve Veri Seti.....	9
3.2. Metot	14
3.2.1. U-Net algoritması	14
3.2.2. Ön işlem adımları ve iş akışı	17
3.2.3. İstatistiksel analiz.....	21
3.2.3.1. Karışıklık matrisi	21
3.2.3.2. Sınıflandırılmış görüntülerde performans ölçümü	22
3.2.4. Kullanılan yazılımlar ve kütüphaneler.....	23
3.2.5. Model eğitiminde kullanılan donanımlar	24
4. BULGULAR VE TARTIŞMA	25
4.1. Modelin Öğrenme Süreci	25
4.2. Üretilen Modelin Doğruluğu	26
4.3. Test Sonuçları Ve Performans Analizleri.....	27
4.3.1. Rotterdam veri seti üzerindeki test sonuçları	27
4.3.2. İzmir veri seti üzerindeki test sonuçları.....	30
5. SONUÇLAR	37
6. KAYNAKLAR	40
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Metotları Kullanılarak SAR (Sentetik Açıklıklı Radar) Görüntülerinden Bina Tespiti.” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

26/01/2022

Recai Alper EMEK



SİMGELER VE KISALTMALAR

Simgeler

cm	: Santimetre
km	: Kilometre
m	: Metre
m ²	: Metrekare

Kısaltmalar

AMS	: American Meteorological Society
BBOX	: Sınır Kutuları (Bounding Box)
CNN	: Evrişimsel Sinir Ağı (Convolutional Neural Networks)
ESA	: Evrişimsel Sinir Ağı
GOC	: Government Of Canada
H	: Yatay (Horizontal)
JSON	: Javascript Nesne Notasyonu (Javascript Object Notation)
MGM	: Meteoroloji Genel Müdürlüğü
NDBI	: Normalleştirilmiş Fark Bina İndeksi (Normalized Difference Built-up Index)
NDVI	: Normalleştirilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index)
RGBNIR	: Kırmızı, Yeşil, Mavi Renk Modeli (Red, Green, Blue, NIR images)
ReLU	: Düzleştirilmiş Doğrusal Birim (Rectified Linear Unit)
RGB	: Kırmızı, Yeşil, Mavi (Red, Green, Blue)
SAR	: Sentetik Açıklı Radar (Synthetic Aperture Radar)
U-NET	: Biyomedikal Görüntü Segmentasyonu için Evrişimsel Ağlar (Convolutional Networks for Biomedical Image Segmentation)
V	: Dikey (Vertical)

ŞEKİLLER DİZİNİ

Şekil 1.1. Polarizasyon (GOC 2021).....	2
Şekil 3.1. Rotterdam veri setine ait çalışma bölgesi	10
Şekil 3.2. Rotterdam veri setine ait çalışma bölgesi (Rotterdam Limanı).....	11
Şekil 3.3. SAR görüntüsü ve bina ayak izleri	11
Şekil 3.4. Bina sınırları	12
Şekil 3.5. İzmir veri seti çalışma alanı	13
Şekil 3.6. İzmir veri seti SAR görüntüsü	14
Şekil 3.7. Evrişimsel sinir ağı (İnik ve Ülker 2017)	14
Şekil 3.8. Doğrusal birim katmanı (Kızrak 2021)	15
Şekil 3.9. Havuzlama katmanı örnek uygulaması (İnik ve Ülker 2017).....	16
Şekil 3.10. Aşırı öğrenme (Balaji 2019)	16
Şekil 3.11. U-Net algoritması (Zhang 2022)	17
Şekil 3.12. Eğitime giren örnek SAR görüntüleri.....	19
Şekil 3.13. İş akışı.....	20
Şekil 4.1. Üretilen modelin doğruluk/epok grafiği	26
Şekil 4.2. Rotterdam veri seti uydu görüntüsü.....	27
Şekil 4.3. Rotterdam veri seti SAR görüntüsü ve sınıflandırılmış görüntü	28
Şekil 4.4. Rotterdam veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi.....	28
Şekil 4.5. Rotterdam bölgesi bina örneklem-1.....	29
Şekil 4.6. Rotterdam bölgesi bina örneklem-2.....	29
Şekil 4.7. Rotterdam bölgesi bina örneklem-3.....	29
Şekil 4.8. Rotterdam bölgesi bina örneklem-4.....	29
Şekil 4.9. İzmir veri seti uydu görüntüsü-1.....	30
Şekil 4.10. İzmir veri seti SAR görüntüsü ve sınıflandırılmış görüntü-1	30
Şekil 4.11. İzmir veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi-1	31
Şekil 4.12. İzmir bölgesi bina örneklem-1	31
Şekil 4.13. İzmir bölgesi bina örneklem-2.....	31
Şekil 4.14. İzmir veri seti uydu görüntüsü-2.....	32
Şekil 4.15. İzmir veri setine ait test SAR görüntüsü-2	33

Şekil 4.16. İzmir veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi-1	33
Şekil 4.17. İzmir bölgesi bina örneklem-2.....	34
Şekil 4.18. İzmir bölgesi bina örneklem-2.....	34
Şekil 4.19. İzmir bölgesi bina örneklem-2.....	34



ÇİZELGELER DİZİNİ

Çizelge 1.1. Radar elektromanyetik spekturumu (AMS 2021).....	2
Çizelge 3.1. Piksel sınıflandırma sistemi.....	21
Çizelge 3.2. Duyarlılık ve kesinlik (Aşçı 2021).....	22
Çizelge 3.3. F1 skoru (Hasan 2020).....	22
Çizelge 4.1. Rotterdam test verisi sınıflandırma doğruluğu.....	29
Çizelge 4.2. İzmir test verisi-1 sınıflandırma doğruluğu.....	32
Çizelge 4.3. İzmir test verisi-2 sınıflandırma doğruluğu.....	34



1. GİRİŞ

Dünya nüfusundaki hızlı artışla birlikte kentsel alanlardaki değişim ve gelişimlerin izlenmesi, incelenmesi ve yönetilmesi çevresel, sosyal ve ekonomik olarak günümüzde daha önemli bir hale gelmektedir (Delibaşoğlu 2020). Son yıllarda gelişen uzaktan algılama metot ve teknolojileri ile bu misyon daha ekonomik ve hızlı bir şekilde yerine getirilmektedir. Ayrıca geliştirilen evrimsel sinir ağı temelli derin öğrenme algoritmaları sayesinde semantik sınıflandırma yöntemleri sınıflandırma ve nesne tespiti çalışmalarında başarılı sonuçlar vermektedir.

Kentsel alanların değişimlerinin izlenmesindeki en önemli hedeflerden biri bina ve yapılarıdır. Binalar şehir planlama, şehir simülasyonları, belediye çalışmaları, doğal afet çalışmalarında önemli bir rol oynamaktadır. Uydu görüntüleri binaların tespiti ve güncellemeleri için verimli kaynaklardır (Demir ve Kaynarca 2018). Binaların sürekli olarak gözlenmesi ve anlamlı analizler yapılması önem arz etmektedir.

Pasif uzaktan algılama ile yapılan gözlemler, hava koşulları ve güneş ışığı gibi parametrelere dayalı olduğundan süreklilik açısından sorun teşkil etmektedir. Bu sorunların çözümü için radar uydularından elde edilen SAR görüntüleri kullanılabilmektedir.

Sentetik Açıklıklı Radar (SAR), birden fazla küçük radar birimi tarafından toplanan radar görüntülerinin elektronik ortamda birleştirilmesiyle normalde daha büyük boyutta tek bir birim tarafından elde edilen görüntüye kıyasla daha yüksek çözünürlük alınabilmesini sağlayan radar türüdür. Birden fazla alıcının anten düzlemine farklı konum ve açılarda yerleştirilmesiyle ortaya çıkan yeni kolektif anten, hedeften hemen her yönde yansıyan radar dalgalarının daha kolay ve doğru şekilde toplanıp karmaşık yüzeyli cisimlerin de değerlendirilmesini mümkün kılar. (Charvat vd. 2011)


SAR görüntülerinin üretildiği radar uyduları birbirlerinden farklı elektromanyetik spektruma sahiptirler. Farklı dalga boylarına sahip bu radar sinyalleri yansıma ve penetrasyon özellikleri bakımından birbirlerinden ayrılırlar. Farklı dalga boylarına sahip olmaları sebebiyle farklı objelerde farklı yansıma değerleri gösterirler. Örneğin büyük dalga boyuna sahip L bandı yoğun bitki örtüsü gibi alanların altına penetre ederek toprak üzerinde yansıma verebilmektedir. Buna istinaden küçük dalga boyuna sahip X ve C bandları daha çok obje yüzeyleri üzerinden yansıma verirler. Bu kapsamda insan yapımı objelerin tespitinde daha çok X ve C bandları kullanılmaktadır. Tez çalışması kapsamında kullanılan veri setlerindeki SAR görüntüleri sırasıyla X ve C banda sahiptir.

Çizelge 1.1: Radar Elektromanyetik Spekturumu (AMS 2021)

Frekans Bandı	Frekans Aralığı (GHz)	Dalga Boyu Aralığı (cm)
L band	1-2	15-30
S band	2-4	7.5-15
C band	4-8	3.75-7.5
X band	8-12	2.5-3.75
Ku band	12-18	1.67-2.5
K band	18-27	1.11-1.67
Ka band	27-40	0.75-1.11
V band	40-75	0.4-0.75
W band	75-110	0.27-0.4

Evrende bulunan tüm elektromanyetik dalgalarda olduğu gibi bir radar dalgasının da hareket yönüne dik gelen düzlemdeki salınımların yönünü tanımlayan polarizasyon özelliği bulunmaktadır.

Polarizasyon genel olarak, elektromanyetik dalganın bir bileşke parametresi olan elektrik alanının oryantasyonunu ifade etmektedir. En çok kullanılan polarizasyon kombinasyonları HH, VV, HV ve VH' dir. Birinci harf gönderilen polarizasyon tipini, ikinci harf ise geri alınanın tipini gösterir. İnsan yapımı objelerin tespitinde HV polarizasyonu daha yüksek yansıma değeri vermektedir. Bu insan yapımı objelerin daha keskin (doğal olmayan) yapısı sayesinde SAR görüntülerinde daha yüksek yansıma alanlarına ve parlak görüme sahip kısımların ortaya çıkmasını sağlar. Bu sayede insan yapımı objeler doğal objelerden ayırt edilebilir.

**Şekil 1.1.** Polarizasyon (GOC 2021)

Aktif ve pasif uzaktan algılama sistemlerinin yorumlanması tek bir görüntü üzerinden de sağlanabilmektedir (Gavankar ve Ghosh 2019). Görünür bölge spektrumuna sahip görüntülerde bu çıplak gözle bile yapılabilirken SAR görüntülerinde birden çok işlem adımlarından geçtikten sonra yapılabilir. Bu tespit işlemlerinin otomatik olarak yapılması amacıyla birbirinden farklı algoritmalar ve yöntemler kullanılması gerekmektedir. Günümüzde bu yöntemler çoğunlukla makine öğrenmesi başlığı altında ele alınmaktadır.

Son yıllarda derin öğrenme ve yapay zekâ kavramlarının kullanım alanları büyük artış göstermekte ve bu artışın temelinde de dünyada halihazırda artış göstermekte olan open-source (açık-kaynak) projeler ve veri setleri yatmaktadır. Özel sektör, üniversiteler ve irili ufaklı devlet yönetimlerinin açık verinin sağladığı katma değere olan farkındalığı artmaya başlamıştır. Açık kaynaklı veri setleri arttıkça yapay zekâ uygulamalarının kullanım alanları artmakta ve doğruluk oranları yükselmektedir.

Derin öğrenme algoritmaları ‘big data’ olarak adlandırılan büyük veri setlerinde daha etkili sonuçlar vermekte ve analizler yapmaya imkân sağlamaktadır. Uzaktan algılama verileri de büyük veri olarak kabul edilmektedir (Liu vd. 2018)

Derin öğrenme kavramına ait temel mimari ESA (CNN) mimarisi kabul edilir. Bu mimari, konvolüsyon, havuzlama, tam bağlı katman ve sınıflandırma katmanından oluşmaktadır. Veri setleri bu katmanlardan ilerler ve öğrenme gerçekleşir. Sonuç olarak ise gerçek sonuçla karşılaştırma yapabilecek bir çıktı verir. Bu çıktı ile girdi arasındaki fark hesaplanır. Daha sonra ise iterasyonlar ve geri yayılım algoritmaları ile ağırlıklar nöronlar arasına dağıtılır. Böylece iterasyonlar boyunca öğrenme devam eder (İnik ve Ülker 2017).

Bir tür Evrişimli Sinir Ağı yaklaşımı (Convolutional Neural Networks-CNN) olan U-Net ilk olarak biyomedikal görüntüler üzerinde daha iyi bir bölütleme (segmentasyon) yapma önerisi ile Olaf Ronneberger, Phillip Fischer ve Thomas Brox (2015) tarafından U-Net: Convolutional Networks for Biomedical Image Segmentation makalesinde duyuruldu. U-Net, Evrişimli Sinir Ağı katmanlarından oluşturulmuş farklı bir mimari ve piksel temelli görüntü segmentasyon (bölütleme) konusunda klasik modellerden daha başarılı sonuç verdiği görülmektedir.

Bina tespiti ve analizlerinin zamandan, mevsimden, hava koşullarından bağımsız yapılması, bu analiz ve tespitlerin yüksek doğrulukla, güncel teknoloji ve metotlar kullanılarak uygulanması amacı ile bu araştırma gerçekleştirilmiştir. Farklı veri setleri ve polarizasyon tipleri kullanılarak sonuçlar karşılaştırılmıştır. Bu çalışmada temeli atılan algoritma, hedef nesneye göre şekillendirilebilir bir yapıdadır. Bu doğrultuda sürdürülebilir ve geliştirilebilir bir metot oluşturmak temel amaçlardan biri haline gelmektedir.

2. KAYNAK TARAMASI

Literatür incelendiğinde son zamanlarda obje tespiti çalışmalarında makine öğrenmesi ve derin öğrenmenin oldukça popüler hale geldiği görülmektedir. Bu durumun temel sebeplerinden biri olan semantik segmentasyonların, geleneksel yöntemlere göre daha iyi sonuçlar vermesidir (Long vd. 2015).

2.1. Uzaktan Algılamada Makine Öğrenimi

Bilgisayar bilimindeki son yıllardaki çalışmalar derin öğrenme modellerin çeşitliliğini artırmış ve belirli amaçlar için kullanılan farklı derin öğrenme metotları ortaya çıkarmıştır. Bu duruma paralel olarak dünya genelindeki uzaktan algılama çalışmalarında da CNN tabanlı derin öğrenme algoritmalarının kullanım sıklığı artmaktadır (Hoerser ve Kuenzer 2020).

Vakalopoulou vd. (2015) tarafından yapılan çalışmada derin öğrenme metotları ile uydu görüntülerinden bina tespiti yapılmıştır. Çalışmada insan yapımı objelerin tespit edilmesi ve izlenmesinin önemi ve zorluğu vurgulanmıştır. Veri setleri analizi aşamasında tüm analizler ikili (binary) halde gerçekleştirilmiştir. AlexNet ağ analizi kullanılmış ve destek vektör makineleri sınıflandırıcısı ile sonuçlar elde edilmiştir. Çıktılar, arazi çalışmaları sonucu elde edilen gerçek verilerle karşılaştırılmış ve doğruluk analizi yapılmıştır. Yapılan analiz sonucu genel doğruluk oranı %90 olarak hesaplanmıştır.

Taff (2018) tarafından geliştirilen interaktif web arayüzünde, kullanıcılar istedikleri alanı Mapbox uydu görüntüleri üzerinden seçmekte ve bu alan içerisinde görüntü sınıflandırma çalışmaları yapılmaktadır. Derin öğrenme metodu olarak U-Net kullanılan çalışmada kodlamalar Python dili ile yapılmıştır. Görüntünün Mapbox uydu görüntüleri tarafından sağlandığı çalışmada, bina ve yol sınırları Open Street Map (OSM) tarafından açık kaynaklı olarak sağlanmaktadır. Tez çalışmasında olduğu gibi bina ve yol sınırlarından ikili görüntüler elde edilerek U-Net algoritmasında maske olarak kullanılmıştır. Sınıflandırılan görüntü interaktif arayüzde görüntülenebilmektedir.

Xu vd. (2018) tarafından yapılan çalışmada yüksek çözünürlüklü uydu görüntüleri, derin öğrenme metotları, yaratılan ekstra katmanlarla zenginleştirilmiş ve semantik sınıflandırma gerçekleştirilmiştir. Belli aralıklarla çıkan sonuçlardaki tuz-biber etkisi giderilmiştir. Ayrıca yüksek çözünürlüklü uydu görüntüleri, makine öğrenmesi modelleri uygulanmadan belirli ön işlem adımlarından geçmiştir. Çalışmada Almanya'nın Vaihingen ve Postdam bölgelerine ait açık kaynaklı uydu görüntüleri kullanılmıştır. 5 cm mekânsal çözünürlüğe sahip bu görüntülerin %80 ile derin öğrenme metodu olan Res-U-Net algoritması eğitilirken, %20'lik kısmı ise doğrulama veri seti olarak kullanılmıştır. R, G, B, NIR kanallarının yanında NDVI bandı hesaplanmış olup eğitime doğruluğunu önemli ölçüde artırmıştır. Çalışmanın sonucundaki doğruluk iki bölge için sırasıyla %96.91 ve %97.71 olarak hesaplanmıştır.

Derin öğrenme metotları ile arazi ve tarla sınırlarının tespitini gerçekleştiren Waldner ve Diakogiannis (2020), son yıllarda arazi ve ürün yönetimde dijitalleşmenin önemini vurgulamaktadır. Hızla dijitalleşen dünyada tarım arazilerin dijital ikizlerini sürekli ve yüksek doğrulukta oluşturmak zaman ve maliyet başta olmak üzere pek çok konuda büyük avantajlar sağlamaktadır. Geliştirilen yöntemde Res-U-Net derin öğrenme algoritması kullanılmıştır. Veri seti üç ana konunun tespitinde kullanılmıştır. Bunlar; arazi alanları, arazi sınırları ve en yakın arazi şeklindedir. Hedefleri bu şekilde belirlemek modelin performansını ve doğruluğunu artırmıştır. Sentinel-2 uydu görüntülerinin kullanıldığı çalışmada model belirli periyotlarla test edilmiş, sezonluk ve iklimsel olarak doğruluğun değişimi incelenmiş ve gösterilmiştir.

Zhao vd. (2019) tarafından yapılan çalışmada insansız hava araçlarından elde edilen görüntüler kullanılarak derin öğrenme metotları ile ürünlerin uç kısımlarından yararlanarak hasat edilmelerini zorlaştıran “Lodging” durumu tespit edilmiştir. U-Net derin öğrenme algoritması kullanılan çalışmada havasal görüntüler, yüksek çözünürlüklü band ve kırmızı, yeşil, mavi bandların senkronize olarak işleminden geçirilmesi ile elde edilmiştir. Yerden 100 metre yükseklikten elde edilen görüntüler, multispektral ve RGB versiyonları olarak ikiye ayrılmış ve sonuçlar karşılaştırılmıştır. Çalışma sonucunda RGB görüntülerin multispektral görüntülere göre daha yüksek doğrulukta sonuç verdikleri saptanmıştır.

Derin öğrenme ve hava fotoğrafları kullanılarak yol tespitinin yapıldığı çalışma Alshaikhli vd. (2019) tarafından gerçekleştirilmiştir. Yol ağlarının güncel tutulması şehir planlaması, trafik yönetimi, kriz yönetimi gibi konularda büyük önem taşımaktadır. Klasik yöntemlere alternatif geliştirilen bu çalışmada zaman ve bütçe konusunda büyük kazanımlar elde edilmiştir. Geliştirilen metodun farklı kısımlarında U-Net algoritması ve konvolüsyon katmanları kullanılmıştır. Bunun sonucunda daha iyi sonuç yakınsaması elde edilmiştir. Ayrıca küçük veri setlerinde de yüksek doğruluk elde edildiği gösterilmiştir.

Öçer (2020) tarafından yapılan çalışmada Google uydu görüntüleri kullanılarak otomatik gemi tespiti yapan bir metot önerilmiştir. R-CNN algoritmasının kullanıldığı çalışmada, görüntüler üzerindeki ölçek engelini aşmaya yönelik öneriler sunulmuştur.

Tek bir sınıfa ait objelerin tespitinin yanı sıra birden çok obje kümesi tespiti yapan çalışmalarda başarılı sonuçlar vermektedir (Sommer vd. 2017). Bu çalışmada R-CNN algoritması ile üretilen bir model önerilmiştir. Çalışmanın sonucunda araba ve tır nesneleri %86.8 doğruluk oranı ile tespit edilmiştir. Zhong vd. (2018) tarafından yapılan çalışmada da çıktı uzayında birden çok sınıf tespiti gerçekleştirilmiştir.

Derin öğrenme metotları ile büyük ölçekli eğitim kümelerinin yanında küçük ölçekli eğitim grupları ile de çalışmalar yapılmaktadır. Küçük ölçekli görüntülere daha fazla obje sığıdığından örneklem uzayı büyüktür ve farklı zorluklarda barındırmaktadır

(Deng vd. 2018). Çalışmada bu zorluklar hava fotoğraflarının yanında SAR görüntüleri kullanılarak ortadan giderilmeye çalışılmıştır. Aktif ve pasif uzaktan algılama metotlarıyla üretilen veri setleri ve modelleri birlikte kullanılmıştır.

Elektro optik görüntülerinin yanı sıra son yıllarda sentetik açıklıklı radar görüntülerinde de makine öğrenmesi ve derin öğrenme algoritmalarının sıklıkla kullanıldığı görülmektedir (Zhu vd. 2017). Bu trend SAR görüntülerinin makine öğrenme algoritmaları ile 2006 yılında tanışmasının ardından başlamıştır (Zhu vd. 2021).

Özellikle görüntü işlemede son yıllarda Tam bağlı katmanlardan oluşan ve CNN temelli algoritmalar ana akımı oluşturmaktadır. U-Net algoritmasında tam bağlı katman olmadan da yüksek doğruluklar elde edildiği paylaşılmaktadır (Ghaffarian vd. 2021).

SAR görüntülerde obje tespiti birçok alt başlık altında toplanmaktadır. Bunlardan bir tanesi de insan yapımı objeler, özellikle de binalardır.

Kaynarca ve Demir (2018) tarafından yapılan çalışmada Sentinel 1A uydusuna ait SAR görüntüleri ve Göktürk-2 uydusuna ait multispektral görüntüler kullanılarak şehir alanlarında bina tespiti yapılmıştır. Aktif ve pasif uzaktan algılanma verilerinin kentsel bölgelerin tespitinde kullanışlı birer araç olduğu vurgulanmıştır. Sırasıyla destek vektör makinaları algoritması Göktürk multispektral görüntüler üzerinde, bulanık mantık algoritmaları ise SAR görüntüleri üzerinde uygulanmıştır. Bu sayede iki veri setinin getirdiği avantajlardan yararlanılmıştır. Son aşamada ise iki sonuç üzerindeki kesişimler sonucu bina tespiti gerçekleştirilmiştir.

Adamo vd. (2010) tarafından yapılan çalışmada yüksek çözünürlüklü SAR görüntülerinde bina izi (footprints) tespiti yapılmıştır. Geliştirilen yöntem, geleneksel metotların aksine tek bir görüntüye uygulanabilmektedir. Bulanık mantık algoritmaları 1 metre mekânsal çözünürlüğe sahip TerraSAR-X uydusuna ait SAR görüntüleri üzerine uygulanmıştır. Çalışma sonucunda orta ve büyük ölçülerdeki binaların yüksek doğrulukta tespiti sağlanmıştır.

Çok zamanlı yüksek çözünürlüklü SAR görüntüleri kullanarak binalardaki değişimi izleyen çalışma Marin vd. (2015) tarafından yapılmıştır. Çalışmada binalar üzerindeki geri saçılma şiddetinin artış veya azalış bilgileri toplanarak kaydedilmiş ve analiz gerçekleştirilmiştir. Çalışmanın ana amacı doğal afetler yüzünden yıkılmış veya hasar görmüş binaları tespit etmektir. Önerilen metot 2009 yılındaki İtalya'nın L'Aquila şehrinde gerçekleşen deprem senaryosunda test edilmiş ve başarıyla yıkılan binaları tespit edebilmiştir.

Derin öğrenme metotları ve yüksek çözünürlüklü SAR görüntülerinden bina tespiti yapılan diğer çalışma Xu vd. (2017) tarafından gerçekleştirilmiştir.

Tek bir metodun tüm SAR görüntüleri üzerine uygulanamamasının getirdiği kısıtlılığa dikkat çeken uygulama tüm SAR görüntüleri üzerinde uygulanabilecek yeni bir metod önermektedir. Önerilen bu metod Terrasar-X uydusundan ve insansız hava araçları ile çekilmiş SAR görüntüleri üzerinde uygulanmıştır. HH, VV, HV polarizasyonlarında test edilen metod %92'nin üzerinde bir doğruluk sağlamıştır.

Yine son yıllarda oldukça popüler olan SAR görüntülerinden gemi tespiti çalışmalarının başarılı örneklerinden biri Kang vd. (2017) tarafından gerçekleştirilmiştir. R-CNN derin öğrenme algoritmasının kullanıldığı çalışmada büyük ölçekli gemilerin yanında çeşitli BBOX (Sınır Kutuları) kullanılarak küçük ölçekli gemilerin tespiti yüksek doğrulukla sağlanmıştır.

Chen ve Wang (2014) tarafından yapılan çalışmada CNN derin öğrenme metodu SAR görüntülerine uygulanmış ve askeri hedefler tespit edilmiştir. Büyük boyutlu SAR görüntüleri birçok alt görüntüye bölünmüş ve eğitim gerçekleştirilmiştir. Üç farklı hedefi içeren veri setinin eğitimi sonucunda %90.1, on farklı hedefi içeren veri setinin eğitimi sonucu ise %84.7 oranında doğruluk sağlanmıştır. Bu hedefler içerisinde sadece binalar değil tank, askeri sığınak, savaş aletleri gibi objelerde bulunmaktadır.

Wilmanski vd. (2016) tarafından yapılan çalışmada 128x128 boyutlarındaki SAR görüntülerinden araç tespiti yapılmıştır. Makine öğrenmesi modelinin geri yayılım kısmında birden çok algoritmanın birlikte kullanıldığı çalışmada, %98 doğruluk oranına ulaşılmıştır.

Wu ve Hou (2021) tarafından yapılan çalışmada gemi tespiti çalışmaları için özelleştirilmiş olan ISASDNet derin öğrenme algoritması kullanılarak SAR görüntülerinden gemi tespit çalışması yapılmıştır. Derin öğrenme algoritmasında maske olarak kullanılacak olan görüntüler çıkartılırken geleneksel morfolojik yaklaşımlar kullanılmıştır. Farklı boyuttaki gemiler, kıyıdaki objeler ve gemiler mesafenin obje tespitindeki doğruluğu azalttığı aktarılmaktadır. Model eğitimi boyunca BBOX (sınır kutuları) kullanılmıştır.

Kontrolsüz sınıflandırma ve CNN tabanlı makine öğrenmesi algoritmalarının beraber kullanıldığı çalışmada %89 oranında doğruluk ve %94 oranında hassasiyet hesaplanmaktadır. CNN temelli makine öğrenmesi modelinin aktivasyon fonksiyonundan sonra destek vektör makineleri algoritması uygulanmıştır. Veri seti %80 eğitim seti %20 test seti olarak ikiye ayrılmıştır. Bunun sonucunda SAR görüntüleri üzerinde yüksek hassasiyette obje tespiti yapılabilmektedir.

Askeri keşif ve gözetleme çalışmalarında SAR görüntüleri sıklıkla kullanılmaktadır. SAR görüntülerinden obje tespiti yapan geleneksel metodlar birçok parametrenin bilinmesine ihtiyaç duymaktadırlar. Bu durumun temel sebeplerinden biri SAR görüntülerinin birbirinden farklı konfigürasyonlar içermesidir. Çalışma kapsamında Evrişimsel Sinir Ağı tabanlı makine öğrenme metodları ile geliştirilen algorithma,

farklılaşan konfigürasyon etkileri giderilerek genele uygulanabilen bir model elde edilmiştir. Farklı büyüklüklerdeki araçlar farklı açılar ve mesafeler test alanına yerleştirilmiş ve Yun-7 test platformu üzerine yerleştirilen radar anteni ile SAR görüntüleri oluşturulmuştur. Çalışma sonuncunda %95 doğrulukla nesne tespiti sağlanmıştır.

Literatür incelendiğinde derin öğrenme algoritmaları, elektro optik görüntülerin yanı sıra SAR görüntüleri üzerinde de başarılı sonuçlar verdiği görülmüştür (Xu vd. 2017). Semantik sınıflandırma konusunda başarılı olan CNN tabanlı bu algoritmalarından biri olan U-Net algoritması medikal görüntülerin yanı sıra elektro optik uydu görüntüleri üzerinde uygulanmış ve başarılı sonuçlar vermiştir (Zhao vd. 2019). U-Net algoritması daha önce SAR görüntüleri üzerine uygulanmamıştır. Sunulan tez kapsamında U-Net algoritmasının SAR görüntüleri uygulanabileceği bir metot önerilmiştir. Sınıflandırmayı desteklemek adına elektro optik uydu görüntüsü, bina sınırlarını içeren vektörel verilerin yanında yeni veri setleri türetilmiştir. Makine öğrenmesi metotlarının yanı sıra kontrolsüz sınıflandırma metotları da çalışmaya dahil edilmiş ve hibrit bir model oluşturulmuştur.

3. MATERYAL VE METOT

Bu bölümde, sunulan tez kapsamında geliştirilen yönteme ait bilgilere yer verilmiştir. Birinci kısımda uygulamaların gerçekleştirildiği çalışma alanları gösterilmiş ve alanlara ait kısa bilgiler verilmiştir. Çalışma alanlarının yanı sıra kullanılan veriler detaylı olarak aktarılmıştır. Ardından uygulanan metot ve kullanılan algoritmalar detaylandırılmış, Şekil 3.13'te iş akış diyagramı verilmiştir. Son kısımda ise kullanılan programlar, kütüphaneler ve donanım bilgileri listelenmiştir.

3.1. Çalışma Alanları ve Veri Seti

Sunulan tez kapsamında iki farklı bölgeye ait iki farklı veri seti kullanılmıştır. Bu çalışma alanlarından ilki Spacenet firmasının 2020 yılında düzenlediği Multi – Sensor All-Weather Mapping yarışması kapsamında açık kaynaklı olarak paylaşılan Hollanda'nın Rotterdam bölgesine ait 120 km² alanı kapsayan bölgedir. Yoğun bina ve liman alanlarına sahip bölge, karışık ve yoğun yapılaşma oranı ile ideal bir araştırma ve geliştirme alanı olarak göze çarpmaktadır.


Rotterdam Hollanda'nın güney batısında bulunan bir şehirdir. Bölgede ılıman okyanus iklim özellikleri hakimdir (Eliçalışkan 2021). Bölgenin yıllık ortalama sıcaklığı ise 9,6 °C'dir. Ortalama nem ise 83%'dür. Hollanda toprakları %32 oranında tarım toprakları, %40 oranında çayır ve meralar, %18 oranında ise orman alanlarından oluşmaktadır. Ormanlar meşe ve huş ağaçlarından meydana gelmektedir. Süpürge otları, katırtırnağı, ardıç ağacı ve fundalıklar bitki örtüsünün büyük çoğunluğunu oluşturur (Wheather Spark 2021).

Rotterdam bölgesi Avrupa'nın en büyük limanına sahiptir. Bölgede irili ufaklı binlerce bina, araç, gemi ve tekne bulunmaktadır. Bu da SAR ve optik görüntülerin füzyonunun test edilmesi için ideal ortamı sunmaktadır. Veri seti, yüksek yoğunluklu kentsel ortamlar, kırsal tarım alanları, banliyöler, endüstriyel alanlar da dahil olmak üzere heterojen bir topoğrafyayı kapsamaktadır.

Bölgeye ait veri seti SAR ve yüksek çözünürlüklü RGBNIR (Red, Blue, Green, Near Infrared) görüntülerinden ve binaların koordinatlı sınırlarının bulunduğu (building footprints) Json formatındaki vektörel verilerden oluşmaktadır.




Şekil 3.1. Rotterdam veri setine ait çalışma bölgesi



Şekil 3.2. Rotterdam veri setine ait çalışma bölgesi (Rotterdam Limanı)

HH, HV, VV, VH polarizasyon türlerini içeren toplam 20 adet X band SAR görüntüsünün mekânsal çözünürlükleri 50 cm'dir. Görüntüler 900x900 piksel boyutuna sahiptir.

Kırmızı, yeşil, mavi ve yakın kızılötesi bandlarına sahip 20 adet RGBNIR elektro optik uydu görüntüsünün mekânsal çözünürlükleri 50 cm'dir. Görüntüler 900x900 piksel boyutuna sahiptir.



Şekil 3.3. SAR görüntüsü ve bina ayak izleri

Json olarak sunulan bina sınırları verileri daha sonra ikili (binary) görüntülere dönüştürülecek ve U-Net derin öğrenme algoritmasında maske sınıfı olarak kullanılacaktır.



Şekil 3.4. Bina sınırları

İkinci veri seti ise İzmir ilinin bir kısmını kapsamaktadır. Türkiye'nin Ege bölgesinin içerisinde yer alan İzmir'de Akdeniz iklimi görülmektedir. Yazları sıcak ve kurak kışların ise ılık ve yağmurlu olarak geçmektedir. Yıllık ortalama sıcaklık ise 17,9 °C'dir (MGM 2021). Bölgenin denize yakın kıyılarında maki bitki örtüsü, orta kısımlarında çam ağacı, fıstık ağacı, zeytin ağacı, köknar, sakız ağacı ve dişbudak ağaçları geniş alanlara yayılmaktadır. İzmir ilinin yüksek kesimlerinde ise dağlık alanlara yakın bölgelerinde ise ormanlık alanlar yer almaktadır. Ortalama nem değeri 58%'dir. (Bozkurt 2022).

Veri seti, 2020 Ege Denizi depreminden önce ve sonra olmak üzere iki adet C band SAR görüntüsünden oluşmaktadır. Bu kapsamda aynı bölgeye ait 2019 ve 2020 tarihli 9800x8500 boyutlarında ICEYE verisi 250x250 piksel alt görüntülere bölünerek test veri seti oluşturulmuştur.

Veri setinin deprem öncesi ve sonrası şeklinde olması, geliştirilen metoda uygun bir test alanına sahip olduğunu göstermektedir. Diğer bir ifade ile deprem ile ilgili araştırma ve geliştirmeler hava koşullarından ve güneş ışığından bağımsız olarak devam edebilecektir.

Hava fotoğraflarının yanı sıra bina zeminlerinin sınırlarına gösteren vektör veri seti .SHP uzantılı olarak sağlanmıştır. Veri seti için ön işlemler gerçekleştirilerek bina sınırları verisi SAR görüntüleriyle kesişim işlemine tutulmuş ve veri seti için gereksiz olan binalar elemine edilmiştir. SAR görüntüsünün sınırları içerisinde kalan vektörel haldeki bina verileri vektör-raster dönüşümü yapılarak ikili (binary) görüntü haline getirilmiştir. Elde edilen binary görüntüler sonrasında doğruluk analizi için kullanılmıştır.



Şekil 3.5. İzmir veri seti çalışma alanı



Şekil 3.6. İzmir veri seti SAR görüntüsü

3.2. Metot

Çalışma kapsamında SAR, optik görüntüler ve vektörel bina sınırları verileri ile entegrasyon sağlanarak bina tespiti yapılmak üzere bir yöntem önerilmiştir. Sağlanan veri entegrasyonu ve ön işleme adımlarından sonra Evrişimsel Sinir Ağı (ESA) temelli derin öğrenme metotlarından olan U-Net algoritması kullanılarak Rotterdam'a ait veri seti üzerinde sınıflandırmayı yapacak olan model eğitilmiştir. Rotterdam veri setinin 80%'i eğitim veri seti 20%'lik kısmı ise validasyon veri seti olarak kullanılmıştır. 80%-20% lik oranın görüntü sınıflandırma sonuçlarında başarılı sonuçlar verdiği görülmektedir (Dhaya 2021). Üretilen model her iki veri seti üzerinde test edilmiştir.


3.2.1. U-Net algoritması

Bu bölümde son yıllarda segmentasyon çalışmalarında kullanım sıklığı artan U-Net algoritması detaylı olarak anlatılmıştır.

Biyomedikal görüntüler üzerinde semantik sınıflandırma yapmak amacıyla geliştirilen U-Net algoritması, derin öğrenme metotlarının temel yapı taşlarından olan Evrişimsel Sinir Ağı katmanı üzerine kurulmuştur (Ronneberger vd. 2017). Kaynak taramasında görüldüğü üzere U-Net algoritması uydu ve SAR görüntüleri üzerinde başarılı sonuçlar vermektedir.

U-Net, Evrişimsel Sinir Ağı (ESA) tabanlı bir derin öğrenme algoritmasıdır. ESA, görüntü işleme için derin öğrenme kavramına ilişkin bir tasarımıdır. Bu tasarımda birincil aşamalar Konvolüsyon (Convulation) ve Havuzlama (Pooling) katmanlarından oluşur.

Son aşama Tam Bağlı katmandan oluşmaktadır. Bununla birlikte sınıflandırma katmanı da bulunmaktadır (İnik ve Ülker 2017).




Şekil 3.7. Evrişimsel sinir ağı (İnik ve Ülker 2017)

Giriş katmanında veri ham olarak ağa aktarılmaktadır. Tasarlanması istenen modelin başarısı, giriş katmanındaki verinin boyutunda önem kazanmaktadır. Giriş katmanındaki görüntü boyutunun yüksek seçilmesi yüksek bellek ihtiyacı, eğitim süresi ve her görüntüye düşen test süresini uzatabilir. Uygulama boyunca sıralanan kriterler göz önünde bulundurularak, tek bandlı (HV) görüntü kullanılmıştır.

Evrişimsel Sinir Ağı'nın temeli de olan konvolüsyon katmanı, dönüşüm katmanı olarak da adlandırılır. Dönüşüm işlemi sabit bir filtrenin olağan görüntü üzerinde dolaştırılması işlemine dayanır. Bu sayede istenilen filtreler görüntülere uygulanarak özellik haritası (features map) oluşturulur.


Konvolüsyon katmanlarından sonra gelen ve ESA nöronlarının çıktılarını istenilen aralığa indirgenmesini sağlayan doğrusal birim katmanı, konvolüsyon katmanından doğrusal olarak çıkan görüntünün doğrusallığını kaybetmesini, negatif değerlerin sıfıra çekilmesini sağlamaktadır. Bu katman modelin öğrenme hızını en çok belirleyen katmanların başında gelmektedir. Geliştirilen metotta düzleştirilmiş doğrusal birim katmanı (ReLU) kullanılmıştır.



Şekil 3.8. Doğrusal birim katmanı (Kızrak 2021)


Havuzlama genel olarak ReLu katmanından sonra gelmektedir. Havuzlama katmanı giriş boyutunu (Genişlik ve Yükseklik), kendinden sonraki konvolüsyon katmanı için azaltmaktadır. Havuzlama katmanındaki işlem aşağı örnekleme (down sampling)

olarak da adlandırılır. Bu katmandaki boyutun azalması durumu bilgi kaybı oluşturmaktadır. Bu bilgi kaybının çeşitli avantajları bulunmaktadır. Bunlar; kendinden sonraki katmanlar için hesaplama yükünün azalması ve sistemin modeli aşırı öğrenmesine (over fitting) engel olmasıdır. U-Net algoritmasında havuzlama metodu olarak maksimum havuzlama filtresi kullanılmaktadır.



Şekil 3.9. Havuzlama katmanı örnek uygulaması (İnik ve Ülker 2017)


Aşırı öğrenme olarak bilinen over fitting tanımı makine öğrenmesi modelinin oluşturulması sırasında ortaya çıkabilen ve oluşturulan modelin eğitim verisi dışında verimli olarak çalışmasını engelleyen bir durumdur. Bu durum modelin veri setini ezberlemesi olarak da adlandırılmaktadır. Model, validasyon verileri kullanılarak eğitim süreci boyunca test edilir. Modelin aşırı öğrendiğinin tespit edildiği durumlarda farklı parametrelerle tekrar kurgulanır.



Şekil 3.10. Aşırı öğrenme (Balaji 2019)

Geliştirilen algorithmada semantik segmentasyon gerçekleştirmek adına Evrişimli Sinir Ağı tabanlı U-Net algoritması kullanılmıştır. U-Net algoritmasını özel kılan durumlar şu şekilde açıklanmaktadır. Evrişimli Sinir Ağı modeli boyunca yükseklik ve genişlik üzerinde uygulanan boyut azaltma modeli bir diğer aşamada ise boyut artırma olarak uygulanır. Buradaki temel hedef, katmanlar aracılığıyla elde edilen çıktının çözünürlüğünü artırmaktır. Model boyunca yüksek çözünürlüklü özellikler ve örneklenen çıktı bir araya getirilir.

Art arda sıralanan evrişim katmanını daha kesin bir çıktı oluşturmak için bu bilgiyi temel almaktadır. Görüntülerin sürekli şekilde parçalanabilmesi amacıyla sınır bölgesinde bulunan pikseller görüntünün etrafına bakışumlu bir şekilde eklenir. Bu teknik ile görüntü sorunsuz bir şekilde parçalanır. Adını U şeklindeki iş akış diyagramından alan U-Net algoritmasında tam bağlı katman bulunmamaktadır. Tüm işlemler konvölüsyon katmanları ile gerçekleştirilir. Bu tasarımın ikinci yarısı en önemli kısmını oluşturmaktadır. İkinci yarı boyunca havuzlama, doğrusal birim ve konvölüsyon katmanları ile boyutu azalan görüntü eski boyutuna ulaşır ve nihai çıktı elde edilir.



Şekil 3.11. U-Net algoritması (Zhang 2022)

3.2.2. Ön işlem adımları ve iş akışı

Geliştirilen ön işlem adımları ve iş akışı bu bölümde sırasıyla ele alınmıştır.

U-Net derin öğrenme metodu ile öğrenme gerçekleşmeden önce sınıflandırma doğruluğunu artırmak amacı ile birçok ön işlem adımı geliştirilmiştir. Tüm algoritma ve işlemler Python programlama dili kullanılarak tasarlanmıştır. Başlangıçta birden çok görüntünün paralel olarak işleme tabi tutulabilmesini sağlayan jeneratörler oluşturulmuştur. Bu sayede işlem süresi kısaltılmış olup işlemci ve ekran kartı üzerinde kullanılması gereken yüksek bellek ihtiyacı azaltılmıştır.

Daha sonra kırmızı ve yakın kızılötesi bandlar kullanılarak normalize edilmiş fark bitki örtüsü indeksi (NDVI) bandı üretilmiştir. Üretilen NDVI bandı veri setine eklenerek genel doğruluğun artırılması hedeflenmiştir.

Üretilen bu NDVI bandı sayesinde bitkiler tespit edilmiş ve olası yanlış sınıflandırmaların önüne geçilmiştir. Çalışma boyunca sahip olunan veri setlerinin geliştirilmesi ve zenginleştirilmesi için yoğun çaba sarf edilmiştir.

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (3.1)$$

Genel sınıflandırma doğruluğunu artırmak için üretilen bir diğer veri seti ise optik görüntü üzerinden kontrolsüz sınıflandırma yöntemleri ile bina sınırlarının tespit edilmesidir. Üretilen bu veri seti JSON formatında iletilen vektörel bina sınırlarını destekleyici nitelikte kullanılmıştır. Kırmızı, yeşil, mavi ve NDVI bandlarına uygulanan K-ortalamlar (K-Means) algoritması ile bina alanları tespit edilmiştir. Tespit edilen bina sınırlarına ait ikili görüntü elde edilmiş ve maske olarak kullanılmak üzere kaydedilmiştir.

Veri seti içerisinde bulunan JSON formatındaki bina sınırları verisinden de ikinci bina maskesi üretilmiş ve ikili görüntü olarak saklanmıştır.

Oluşturulan ikinci bina maskesi SAR görüntüsünün HV bandına uygulanmış, bina sınırları içerisinde kalan SAR saçılma değerlerinin ortalama değeri hesaplanmıştır. Daha sonra K-Ortalamlar yöntemi ile elde edilmiş bina sınıfı maskesi HV bandına uygulanıp ikinci maske üzerinden elde edilen ortalama değerden yüksek yansıma değerine sahip piksellerde bina sınıfına dahil edilmiştir. Bu sayede iletilen sayısal veride bina sınıfına ait olmayıp SAR ve RGB görüntülerde bina sınıfına ait olan pikseller doğru sınıflandırılmıştır. Bu farklılığın temel sebebi ise JSON formatındaki bina sınırı verisinin binanın zemine oturduğu alanı kapsamasıdır.

Uydu görüntüleri üzerinde binaların çatısında veya balkonlarında var olan çıkıntılar da bina sınıfına ait olmalıdır. Bu sayede genel sınıflandırılma doğruluğunun artırılması hedeflenmiştir.

İki maskenin sonucunda oluşan kesin bina sınırları işaretlenmiş ve final bina sınıfı maskesi oluşturulmuştur. Oluşturulan bina sınıfı maskesi U-Net algoritmasında modelin eğitimi ve doğruluğun hesaplanması konularında kullanılmıştır.


Orijinal girdiler, üretilen girdiler ve final maskesi U-Net algoritması ile eğitilmiştir.



Şekil 3.12. Eğitime giren örnek SAR görüntüleri

Şekil 3.12’de görüldüğü üzere eğitim verileri kentsel alanların ve liman bölgelerinin bulunduğu alanlardan seçilmiştir.

Toplamda 20 adet SAR görüntüsü üzerinde eğitilen model, test verilerine uygulanmış ve bina tespiti çalışması gerçekleştirilmiştir. Tespit sonrasında doğruluk matrisleri oluşturulmuştur.



Şekil 3.13. İş akışı

3.2.3. İstatistiksel analiz

Geliştirilen model test görüntülerine uygulanarak bina sınıfı tespit edilmiştir. Tespit edilen bina sınıfının doğruluk analizi için karışıklık matrisi kullanılmıştır.

3.2.3.1. Karışıklık matrisi

Karışıklık matrisi, eğitilen model tarafından yapılan tahmin ile gerçek arasındaki bilgilerin kıyaslamasını gösteren matristir. Makine öğrenmesi algoritmalarında modellerin sınıflandırma doğruluğunu sağlamak amacıyla kullanılmaktadırlar. Her bir sınıf için ayrılan değerler sayılarak doğru ve yanlış tahminlerin sayısı ortaya çıkartılır (Hasan 2020). Çalışmadaki doğruluk analizinde kullanılan karışıklık matrisi Çizelge 3.1’de gösterilmiştir.

Çizelge 3.1. Piksel sınıflandırma sistemi

		Tahmin Edilen	
		Negatif (bina yok)	Pozitif (bina var)
Gerçekte	Negatif (bina yok)	a	b
	Pozitif (bina var)	c	d

a, bir pikselin negatif olduğuna dair doğru tahminlerin sayısını ifade eder.

b, bir pikselin pozitif olduğuna dair yanlış tahminlerin sayısını ifade eder.

c, bir pikselin negatif olduğuna dair yanlış tahminlerin sayısını ifade eder.

d, bir pikselin pozitif olduğuna dair doğru tahminlerin sayısını ifade eder.

Gerçek pozitif oran (True Positive- TP), (3.2)’deki gibi hesaplanır (Santra ve Christy 2012). Zeminde bina olan bir pikselin bina olarak işaretlenme sayısını ifade eder.

$$TP = \frac{d}{c + d} \quad (3.2)$$

Yanlış pozitif oran (False Positive- FP), (3.3)’teki gibi hesaplanır (Santra ve Christy 2012). Zeminde bina olmayan bir pikselin bina olarak işaretlenme sayısını ifade eder.

$$FP = \frac{b}{a + b} \quad (3.3)$$

Gerçek negatif oran (True Negative- TN), (3.4)'teki gibi hesaplanır (Santra ve Christy 2012). Zeminde bina olmayan bir pikselin bina değil olarak işaretlenme sayısını ifade eder.

$$TN = \frac{a}{a + b} \quad (3.4)$$

Yanlış negatif oran (False Negative- FN), (3.5)'teki gibi hesaplanır (Santra ve Christy 2012). Zeminde bina olan bir pikselin bina değil olarak işaretlenme sayısını ifade eder.

$$FN = \frac{c}{c + d} \quad (3.5)$$

3.2.3.2. Sınıflandırılmış görüntülerde performans ölçümü

Gerçek pozitif oran, yanlış pozitif oran, gerçek negatif oran ve yanlış negatif oranlar kullanılarak hesaplanan doğruluk değeri (3.6)'da gösterilmiştir (Santra ve Christy 2012).

$$\text{Doğruluk\%} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (3.6)$$

Test verisi üzerine uygulanan modelin performans ölçümü için genellikle doğruluk formülü kullanılmaktadır (Osmanoğlu 2021).

Semantik segmentasyon sınıflandırma çalışmalarında doğruluk tek başına yeterli bir performans ölçümü sağlamamaktadır. Bunun yanında duyarlılık ve kesinlik parametrelerini kullanarak F1 skoru hesaplanır (Lee vd. 2020). F1 skoru ile segmentasyon performansları etkin bir şekilde izlenmektedir. Duyarlılık, kesinlik hesaplamaları Çizelge 3.2'de gösterilmiştir.

Çizelge 3.2. Duyarlılık ve kesinlik (Aşçı 2021)

Duyarlılık	$TP / (TP + FN)$
Kesinlik	$TP / (TP + FP)$

F1 skoru Çizelge 3.3' teki gibi hesaplanır.

Çizelge 3.3. F1 skoru (Hasan 2020)

F1 skoru	$2 \times (\text{Duyarlılık} \times \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik})$
----------	---

Tez çalışması kapsamında F1 skoru, doğruluk, duyarlılık ve kesinlik parametreleri hesaplanmıştır.

3.2.4. Kullanılan yazılımlar ve kütüphaneler

Sunulan tez çalışması kapsamında önerilen yöntemin uygulanması amacıyla aşağıdaki yazılımlardan yararlanılmıştır. İşlem adımlarının tamamı 3.parti uygulamalar kullanılmadan Python dili ile kodlanmıştır. Kullanılan tüm kütüphaneler ücretsiz ve açık kaynak kodludur.

Python programlama dili 1990'lı yılların başında Guido Van Rossum tarafından geliştirilmeye başlanmıştır. Python, geniş bir topluluğu olan ulaşan nesne tabanlı ve dinamik kodlanan bir dildir. Diğer programlama dillerine kıyasla daha az satır kullanarak daha okunaklı kod yazmaya imkân vermektedir. İçerdiği açık kaynaklı modülleri sayesinde ağ modelleme, rest api ve web çatısı oluşturma, grafiksel kullanıcı arayüzü (GUI) tasarımları ve oyun yazılımları geliştirme, web tabanlı uygulamalar, bilimsel hesaplamalar, makine öğrenmesi ve veri madenciliği olmak üzere pek çok kullanım alanı bulunmaktadır (Ayvaz ve Çoban 2016).

Yazılımlar:

- I. Python 3.8.5

Kütüphaneler:

- I. GDAL: Vektör ve Raster veri formatları arasında dönüşüm gerçekleştirilmesini sağlayan kütüphanedir. Açık Kaynak Mekansal Kuruluşu tarafından lisanslanmıştır (GDAL 2021).
- II. GeoJson: GeoJson uzantılı verileri okumayı ve yazmayı sağlayan kütüphanedir. Nokta, çizgi ve alan cinsindeki geometrik objeler oluşturulabilir. Sean Gillies tarafından geliştirilmiştir. (GeoJson Community 2021).
- III. Skimage: Görüntü işleme algoritmalarının koleksiyonlarını barındıran kütüphanedir. Alexandre de Siqueira ve Emmanuelle Gouillart başta olmak üzere gönüllü topluluk tarafından geliştirilmiştir (Scikit Image Community 2022).
- IV. Keras: Derin öğrenme algoritmalarının kolayca kullanılabilirdiği kütüphanedir. François Chollet tarafından geliştirilmiştir (Keras Community 2022).
- V. Numpy: Başlıca bilimsel hesaplamalar ve matris, dize işlemlerinin hesaplamalarında kullanılan pakettir. Sebastian Berg başta olmak üzere Python geliştiricileri tarafından geliştirilmektedir. (Numpy Community 2022). Tez çalışmasında kullanılan çoğu kütüphanenin yapı taşıdır.
- VI. Tensorflow: Geliştiricilerin makine öğrenimi alanındaki en son teknolojiyi kullanmalarını sağlayan esnek bir araçtır. Google tarafından geliştirilmektedir. (Google 2022).

3.2.5. Model eğitiminde kullanılan donanımlar

Tez çalışmasındaki ön işlem adımları ve model eğitimi sürecinde NVIDIA GeForce GTX 1650Ti ekran kartı, AMD Ryzen 5 4600H işlemci ve 24 GB ram kullanılmıştır.



4. BULGULAR VE TARTIŞMA

Bu bölümde Rotterdam’a ait veri setinin eğitimi ile oluşturulan derin öğrenme modelinin doğruluk hesaplamaları ele alınmış, elde edilen sonuçlar ve oranlar gösterilmiştir. Son aşamada ise üretilen model her iki veri setinde test edilmiş ve sonuçlar paylaşılmıştır.

4.1. Modelin Öğrenme Süreci

Önceki çalışmalardaki çıktı ürün olan özellik haritaları dikkate alındığında büyük çoğunlukla iki sınıflı sınıflandırılmalar yapıldığı göze çarpmaktadır. Bunun temel sebeplerinden biri çıktı uzayındaki eleman sayısını daraltarak daha yüksek doğruluklar hedeflenmesidir. Diğer bir ifade ile belirli bir hedefe yönelik model eğitimlerinin yapılmış olmasıdır.

Tez çalışmasında kullanılan iki veri setinde de çıktı kümesi bina ve bina olmayan alanlar olmak üzere ikiye ayrılmıştır. Bina olarak sınıflandırılan pikseller 1 değerini alırken, bina olarak sınıflandırılmayan pikseller 0 değerini almaktadır. Birden fazla etiket içeren örneklem kümelerinde sonuç katmanı sigmoid fonksiyonlar ile aktive edilmektedir (Chen ve Wang 2014). Bu sayede piksel değerleri olasılık olarak ifade edilebilmektedir. Bina sınıfına yakınsayan pikseller 1’e yakın değer alırken, bina sınıfına ait olmayan pikseller 0’a yakın değer almaktadır. Sonuç olarak çıktı uzayı sigmoid fonksiyonu sayesinde 0 ile 1 arasında bir değer almaktadır. Sigmoid fonksiyonu (4.1)’de görülmektedir.

$$S(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (4.1)$$

Yapay zekâ algoritmalarında bir çıktı üretmenin yanı sıra üretilen çıktının doğruluğunun da ölçülmesi gerekmektedir. Elde edilen bu doğruluk ile yapay zekâ algoritmasındaki ağırlık matrisleri güncellenir ve öğrenme işlemleri devam eder.

Çapraz düzensizlik (cross entropy) veya log kaybı (log loss) derin öğrenme sınıflandırma modelinin performansını ölçer. İkili çapraz düzensizlik kayıp fonksiyonu iki sınıflı sınıflandırılmalarda kullanılır (Goodfellow 2016). Modelin eğitimi sırasında eğitim verisinin 1 epok sonunda bir pikseli için y' tahmin değerinin gerçek y değeri ile yakınsama farkının hesaplanmasıdır. Geliştirilen algorithmada kullanılan matematiksel model (4.2)’de gösterilmiştir.


$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (4.2)$$

Hesaplanan log kaybı değeri geri yayılım algoritması ile modelin tüm ağırlıklarına etki eder ve modelin eğitim süreci başarılı bir şekilde devam eder.

İterasyonlar boyunca öğrenme aşamaları devam ederken, bölüm 3.2.1’de anlatıldığı gibi aşırı öğrenme durumuna karşı dikkat edilmelidir. Bu sebeple eğitim boyunca validasyon verileri ile model sürekli olarak test edilmiş ve doğruluk analizi yapılmıştır. Validasyon veri setleri hazır olarak verilmemektedir. Girdi kümesi belirli oranlarda yeni alt veri setlerine bölünerek validasyon veri seti grubu oluşturulur. Modelin eğitiminde kullanılan Rotterdam’a ait veri setinin girdi görüntülerinin %20’lik kısmı validasyon veri seti olarak kullanılmıştır.

4.2. Üretilen Modelin Doğruluğu

Şekil 3.13’te gösterilen iş akışı boyunca ön işleme tabi tutulan Rotterdam’a ait veri seti U-Net algoritmasına girdi olarak entegre edilmiş ve model eğitilmiştir. Modelin eğitimi sonucunda oluşan model doğruluk grafiği Şekil 4.1’de gösterilmiştir.



Şekil 4.1. Üretilen modelin doğruluk/epok grafiği

Şekil 4.1’de görüldüğü üzere model 30 epok boyunca eğitilmiştir. Bu eğitim sonucunda doğruluk %81 olarak hesaplanmıştır. 5. epoktan sonra doğruluk yatay bir seyir halinde ilerlemektedir. Bir diğer ifade ile 5. epokta model optimum öğrenme oranına ulaşmıştır.

Modelin istenilen doğrulukta öğrenme işlemini tamamladığını gösteren diğer bir gösterge ise log kaybı değerinin 0.40 olmasıdır. İdeal bir modelin log kaybı değeri sıfır değerine olabildiğince yakın olmalı ve sıfıra eşit olmamalıdır (Vovk 2015). Log kaybı değerinin sıfıra yakın olmaması örneklem pikselin değeri ile pikselin gerçek sınıfı arasındaki farkın yüksek olması bir diğer ifade ile modelin iyi ve doğru sonuçlara uzak çıktılar vermesi anlamına gelmektedir. Log kaybı değerinin sıfıra eşit olması ise modelin aşırı bir öğrenme gerçekleştirdiği, eğitim veri setini ezberlediği anlamına gelmektedir.

4.3. Test Sonuçları ve Performans Analizleri

Eğitilen U-Net modeli rastgele olarak seçilen üç adet test SAR görüntüsüne uygulanmış ve performans analizleri yapılmıştır. İki adet test verisi İzmir veri setinden, bir adet veri seti ise Rotterdam veri setinden seçilmiştir.


Vektörel bina verisinde bina olup sınıflandırılmış görüntü üzerinde bina olarak işaretlenen pikseller TP (true-positive), bina değil olarak işaretlenen pikseller ise FN (false-negative) olarak işaretlenmiştir. Vektörel bina verisinde bina olmayıp sınıflandırılmış görüntü üzerinde bina olarak işaretlenen pikseller FP (false-positive), bina değil olarak işaretlenen pikseller TN (true-negative) olarak işaretlenmiştir. Bunun sonucunda sınıflandırma doğrulukları hesaplanmıştır.

4.3.1. Rotterdam veri seti üzerindeki test sonuçları

Elde edilen model Rotterdam veri seti içerisinde bulunan test görüntüsüne uygulanıp sonuçlar gözlemlenmiştir. Test SAR görüntüsü ve sınıflandırılmış nihai görüntü Şekil 4.3d’de gösterilmiştir. Sınıflandırmaya giren görüntü ve çıktı uzayı 900x900 piksel boyutlarındadır. Sınıflandırma işlemi sonucu bina olarak işaretlenen pikseller Şekil 4.4 üzerinde sarı renk ile gösterilmiştir.



Şekil 4.2. Rotterdam veri seti uydu görüntüsü



Şekil 4.3. Rotterdam veri seti SAR görüntüsü ve sınıflandırılmış görüntü




Şekil 4.4. Rotterdam veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi

Şekil 4.3d’de görüldüğü üzere bina bölgeleri siyah renk ile işaretlenmiştir. Bina olmayan pikseller ise beyaz renk ile işaretlenmiştir. Zeminde bina olmamasına rağmen bina olarak işaretlenen alanlar bulunmaktadır. Bunun temel sebeplerinden biri, test görüntüsü içerisinde yoğun ağaçlık alanların bulunmasıdır. Test görüntüsü üzerinde çatı şekilleri birbirine benzer yapıda olduğundan bina bölgeleri benzer saçılma özelliği göstermektedirler.


X band SAR görüntüsü üzerindeki tespit edilen bina senaryoları Şekil 4.5, Şekil 4.6, Şekil 4.7 ve Şekil 4.8 üzerinde gösterilmiştir. Bina olarak işaretlenen alanlar siyah renkte gösterilmiştir.




Şekil 4.5. Rotterdam bölgesi bina örneklem-1



Şekil 4.6. Rotterdam bölgesi bina örneklem-2



Şekil 4.7. Rotterdam bölgesi bina örneklem-3



Şekil 4.8. Rotterdam bölgesi bina örneklem-4

Sınıflandırılmış görüntü ile vektörel bina verileri piksel olarak karşılaştırılmış ve performans analizi yapılmıştır. Rotterdam test verisi doğruluk sonuçları Çizelge 4.1’de paylaşılmıştır.

Çizelge 4.1. Rotterdam test verisi sınıflandırma doğruluğu


TP	TN	FP	FN
125415	527867	114104	42614
DUYARLILIK	KESİNLİK	F1 SKOR	DOĞRULUK
0.75	0.53	0.62	0,80

4.3.2. İzmir veri seti üzerindeki test sonuçları

X band SAR görüntüleri üzerinde eğitilen model C band SAR görüntüleri test edilmiştir. İzmir bölgesine ait test görüntülerinin boyutları 250x250 pikseldir. İzmir veri seti üzerinde gerçekleştirilen testin ana hedefi, yüksek mekânsal çözünürlük ve X band SAR görüntüsü üzerinde eğitilen modelin düşük mekânsal çözünürlük ve C band SAR görüntüsü üzerinde elde edeceği doğruluk sonuçlarının araştırılmasıdır. İzmir Veri Seti SAR Görüntüsü-1 sınıflandırma sonuçları Şekil 4.10d’de gösterilmiştir. Bina olarak işaretlenen alanlar siyah renk ile belirtilmiştir. Sınıflandırma işlemi sonucu bina olarak işaretlenen pikseller Şekil 4.11 üzerinde sarı renk ile gösterilmiştir.



Şekil 4.9: İzmir veri seti uydu görüntüsü-1



Şekil 4.10. İzmir veri seti SAR görüntüsü ve sınıflandırılmış görüntü-1




Şekil 4.11. İzmir veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi-1


Şekil 4.9b’de görüldüğü üzere SAR görüntüsünün orta bölümünde ağaçlık bölge bulunmaktadır. Rotterdam test verisinde olduğu üzere C band İzmir test verisinde de ağaçlık bölgeler yüksek yansımaya değeri vermektedir. Bina bölgesine ait yansımaya değeri ortalaması, ağaçlık bölgeye ait yansımaya değeri ortalamasının yaklaşık 1.67 katı olarak hesaplanmıştır.

Şekil 4.9b’de farklı çatı tiplerine sahip binalar gözükmemektedir. Zeminlerin pürüzsüzlüğünün yanında tipleri de radar sinyallerinin geri yansımaya şiddetlerini değiştirmektedir (Wall vd. 2005). Şekil 4.10c’de düz çatılı binalar daha parlak renkte gözükmemektedir. Bu durum pürüzsüz yüzeylerin daha yüksek geri yansımaya özelliğine sahip olmasıdır. Benzer gösterim şekil 4.14c’de de ortaya çıkmıştır.

İzmir veri setine ait ilk test verisindeki bina tespit senaryoları Şekil 4.12 ve Şekil 4.13’te gösterilmiştir. Bina alanları siyah renk ile belirtilmiştir.



Şekil 4.12. İzmir bölgesi bina örneklem-1




Şekil 4.13. İzmir bölgesi bina örneklem-2

İzmir veri seti test verisi-1 üzerinde sınıflandırılmış görüntü ile vektörel bina verileri piksel olarak karşılaştırılmış ve performans analizi yapılmıştır. Doğruluk tablosu Çizelge 4.2’de gösterilmiştir.


Çizelge 4.2. İzmir test verisi-1 sınıflandırma doğruluğu

TP	TN	FP	FN
12841	20798	10663	18198
DUYARLILIK	KESİNLİK	F1 SKOR	DOĞRULUK
0.42	0.55	0.48	0.54

İzmir test veri seti sar görüntüsü-2’ye ait sınıflandırma sonuçları Şekil 4.15d’de gösterilmiştir. Bina olarak işaretlenen alanlar siyah renk ile belirtilmiştir. Test görüntüsü üzerinde yapı/görüntü oranı diğer test görüntülerine göre çok daha yüksektir. Bina olarak işaretlenen pikseller siyah renk ile gösterilmiştir. Sınıflandırma işlemi sonucu bina olarak işaretlenen pikseller Şekil 4.16 üzerinde sarı renk ile gösterilmiştir.



Şekil 4.14. İzmir veri seti uydu görüntüsü-2




Şekil 4.15. İzmir veri setine ait test SAR görüntüsü-2




Şekil 4.16: İzmir veri seti tespit edilen bina sınıfının uydu görüntüsü üzerinde gösterimi-1

Rotterdam örneğinde olduğu gibi İzmir veri setinde de bina alanları tespit edilmiştir. Ancak görüntü üzerinde oluşan gürültüler ilk veri setine göre daha fazladır. Bunun nedeni mekânsal çözünürlüğün ilk veri setine göre daha düşük olmasıdır (1 metre). Bir diğer nedeni ise İzmir SAR görüntülerinin C band kullanılarak oluşturulmuş olmasıdır.


İzmir veri setine ait ikinci test verisindeki bina tespit senaryoları Şekil 4.17, Şekil 4.18 ve Şekil 4.19’da gösterilmiştir. Bina alanları siyah renk ile belirtilmiştir.



Şekil 4.17. İzmir bölgesi bina örneklem-2



Şekil 4.18. İzmir bölgesi bina örneklem-2



Şekil 4.19. İzmir bölgesi bina örneklem-2

İzmir test verisi-2 üzerinde sınıflandırılmış görüntü ile vektörel bina verileri piksel olarak karşılaştırılmış ve performans analizi yapılmıştır. Doğruluk tablosu Çizelge 4.3'te gösterilmiştir.

Çizelge 4.3. İzmir test verisi-2 sınıflandırma doğruluğu

TP	TN	FP	FN
8527	30980	9069	13924
DUYARLILIK	KESİNLİK	F1 SKOR	DOĞRULUK
0.38	0.49	0.43	0.64

En yüksek doğruluk oranı Rotterdam test verisi üzerinde elde edilmiştir. Sonrasında bina/görüntü oranı yüksek olan İzmir test verisi-2 ve İzmir test verisi-1 gelmektedir. Doğruluk hesaplamaları piksel değerleri üzerinden gerçekleştirildiğinden semantik sınıflandırma sonuçlarını belirten f1 doğruluk değerlerine göre düşük değerler almıştır.

Geliştirilen algoritma bina alanlarını C band İzmir veri setine oranla X band Rotterdam veri seti üzerinde daha yüksek doğrulukta tespit etmiştir. Bu durumun oluşmasındaki sebepler mekânsal çözünürlük ve modelin Rotterdam veri seti SAR görüntüsü üzerinde eğitilmiş olmasıdır. Doğruluk farkındaki bir diğer sebep ise Rotterdam veri seti SAR görüntüsünün uçak üzerine yerleştirilen sensörler ile oluşturulmasıdır. İzmir veri seti SAR görüntüsü uydu üzerindeki sensörler ile oluşturulmuştur. Rotterdam veri setindeki piksel boyutları 900x900 iken İzmir veri seti boyutu 250x250'dir.

Bu sınıflandırma doğruluklarından elde edilen sonuç, X band SAR görüntüsü üzerinden eğitilen bir modelin C band ile üretilen SAR görüntüsü üzerinde 59% doğruluk oranı vermesidir. Buna göre X band SAR görüntüleri üzerinde eğitilen derin öğrenme modeli C band SAR görüntüleri üzerinde uygulanabilir.

Geliştirilen algoritmanın binaları başarılı bir tespit gerçekleştirmesinin yanında şekilsel olarak birebir olarak doğru sonuçlar sunamamaktadır. Bitişik nizam bina yapısını içeren örneklerde binalar birbirinden bağımsız olarak tespit edilememektedir. Bunun yerine yapılan tespit, bu bölgede bir bina bloğunun olduğu şeklindedir. Bu durum Şekil 4.19 üzerinde gösterilmiştir.

Segmentasyon çalışmalarında bitki sınıfları ana hedef olmamalarına rağmen tespit edilmiş ve türetilmiş sınıflar olarak algoritmalara katkı sağlamışlardır. Bitki sınıfları kontrolsüz sınıflandırma yöntemlerinin yanında kontrollü sınıflandırma yöntemleri ile de tespit edilebilmektedir. Bunun sonucunda genel doğrulukta artışlar gözlenmektedir (Pi vd. 2020). Önerilen metotta bitki sınıfları NDVI yöntemi ile tespit edilmiş ve K-Means algoritmasına sokularak bitkisel alanların sınıflandırma sonucuna olan etkisini minimize edilmesi amaçlanmıştır.

U-Net derin öğrenme algoritmasının kullanıldığı 3 adet veri seti üzerinde farklı senaryolar dahilinde eğitilen modellerde, gölge etkisinin en az olduğu veri setlerinde daha yüksek doğruluklar hesaplanmıştır (Delibaşoğlu 2020). SAR görüntüleri, objelerin yansıma değerleri yerine saçılma bilgilerini kullanarak objenin geometrik özellikleri ile oluşturulmaktadır. Buradan hareketle gölge durumlarının sınıflandırma doğruluğunu etkilediği şartlarda, makine öğrenmesi modellerinin eğitimini SAR görüntüleri ile gerçekleştirmek, gölge etkisinin yok edilmesinde rol oynamaktadır (Papson ve Narayanan 2012). Tez çalışması daha çok kentsel alanları kapsadığından büyük gölge alanlarına sahiptir. Eğitim sürecinin SAR görüntüleri kullanılarak gölgeli alanların sınıflandırmaya etki etmesinin önüne geçilmiştir.

Küçük veri setleri üzerinde (Xu vd. 2017) geliştirilen modellerde Şekil 4.3'e benzer bir grafik oluşmaktadır. İlk epoklarda hızla yükselen model doğruluk grafiği, eğitim sürecinin orta ve son aşamalarında düz seyretilmektedir. Bu durum modelin erken safhalarda optimum doğruluğa ulaştığının göstergesidir.

Literatürde uydu görüntüleri üzerinde CNN tabanlı algoritmalar ile segmentasyon çalışmaları yapan 261 çalışma incelendiğinde %33 oranında U-Net algoritmasının kullanıldığı görülmektedir. Bunun sonucunda U-Net algoritması ResNet ve SegNet gibi algoritmaları geride bırakarak zirvede yer almaktadır (Hoeser vd. 2020). 7 farklı derin öğrenme metotlarının SAR görüntüleri üzerinde karşılaştırıldığı çalışmada U-Net algoritması Pyramid Scene Parsing Network (PSP) algoritmasının ardından en başarılı algoritma olmuştur (Mehra vd. 2020).

Görüntü üzerinde kenar keskinleştirme işlemi yapan 3x3 boyutunda kernel olan Sobel operatörü uygulamıştır. Bu sayede SAR görüntüleri üzerinde parlak bölgelerde bulunan bina sınırlarının tespit edilebilirliğini artırmak amaçlanmıştır. Evrişimsel Sinir Ağı tarafından filtrelenmiş görüntünün çözünürlüğünde daha az kayıpların yaşanması amacı ile bu boyutta bir kernel tercih edilmiştir. Literatürdeki çalışmalarda Evrişimsel Sinir Ağı modellerinde genellikle 3x3 veya 5x5 boyutlarında kernel boyutları tercih edilmektedir (Arnault 2020).

Önerilen çalışmada U-Net algoritmasının SAR görüntüleri üzerindeki model doğruluğu, uydu görüntülerinden elde edilen türetilmiş katmanlar ile artırılmıştır.

Tez çalışmasındaki ana motivasyon aktif ve pasif uzaktan algılama verilerinin birlikte kullanılarak etkili bir semantik sınıflandırma gerçekleştirmektir. Bu sebeple sadece vektörel bina sınırları ile yetinilmemiş, pasif uzaktan algılama verileri geliştirilen metoda entegre edilmiş ve sonuç maskesi zenginleştirilmiştir. Pasif uzaktan algılama verilerinin eksikliği durumlarında mevcuttaki vektörel bina sınırları farklı dilatasyon teknikleri ile genişletilip bina çıkıntıları – bina tabanı arasındaki fark giderilmeye çalışılabilir. Tüm çalışma boyunca pasif uzaktan algılama verileri SAR görüntüleri üzerinde gerçekleştirilecek sınıflandırma için destekleyici veriler olarak kullanılmıştır.

SAR görüntüleri üzerinde U-Net algoritması kullanılarak bina tespiti yapılan bir çalışma literatürde mevcut değildir. Bu durum çalışmanın özgünlüğünü ve literatüre olan katkısını artırmaktadır. Tez çalışması göstermiştir ki U-Net algoritması optik görüntülerin yanı sıra SAR görüntüleri üzerinde de başarılı bir şekilde uygulanabilmektedir.

5. SONUÇLAR

Kentsel alanlar irili ufaklı birçok insan yapımı objeleri içinde bulunduran yaşam alanlarıdır. Bu alanlardaki nesnelerin sürekli olarak izlenmesi şehir planlama, şehir simülasyonları, belediye çalışmaları gibi konuların yanı sıra deprem, sel ve diğer doğal afetler de yıkılmış / hasarlı binaların tespiti için de önemli bir yere sahiptir. Kentsel alanlarda yapılacak olan olası bina yönetim sistemleri için güncel, sürekli ve doğru bilgi gerekmektedir. Gerek kapsam gerekse maliyet açısından güncel ve doğru bilginin sağlanmasının önemli olduğu düşünülmektedir. Bu kapsamda uzaktan algılama araçları daha da önem kazanmaktadır. Uzaktan algılama araçları ile elde edilen bu veriler, yapay zekâ algoritmaları ile hızlı ve doğru olarak analiz edilecek ve bu sayede sürdürülebilir bir araştırma ve geliştirme süreci gerçekleştirilebilecektir.

Dünya genelindeki uzaktan algılama çalışmalarında CNN tabanlı derin öğrenme algoritmalarının kullanım sıklığı artmaktadır. Tez çalışmasında; CNN tabanlı derin öğrenme algoritmaları kullanılarak, optik görüntülere yönelik yapılan çalışmaların yanı sıra bu algoritmanın SAR görüntüleri üzerinde de kullanılmasıyla farklı görüntüler üzerinde kullanılabilirliği sınanmıştır.

Önerilen yöntemde; SAR, optik uydu görüntüleri ve vektörel bina verileri kullanılarak otomatik bina tespiti yapan bir algoritma geliştirilmiştir. Geliştirilen algoritmada temel amaç, uydu görüntüleri ve vektörel bina verilerini bir destek veri seti olarak kullanarak SAR verilerinin eğitilmesiyle bir derin öğrenme modeli ortaya çıkarmaktır. Oluşturulan bu derin öğrenme modeli, farklı bölgelere ait ve farklı bandlardan oluşan test SAR görüntülerine uygulanmış ve sonuçlar tartışılmıştır. Tüm süreç Python programlama dili ile kodlanmış ve analiz edilmiştir.

Aktif ve pasif uzaktan algılama verilerinin birlikte kullanıldığı çalışmada, iki sisteminde uygun modellemeler altında birbirlerini doğrudan destekledikleri ve bunun sonucunda genel sınıflandırma doğruluğunun arttığı gözlemlenmiştir. Uzaktan algılama veri setleri yanında vektörel olarak sunulan bina sınırı verileri, vektör-raster dönüşümü yapılarak maske haline getirilmiş ve model eğitiminde doğru uzay olarak kullanılmıştır. Halihazırda bulunan veri setlerinin yanında farklı veri setleri türetilmiş ve model eğitime entegre edilmiştir. Bitkileri bina sınıflarından elimine etmek amacıyla NDVI bandı kullanılmıştır. Vektörel veriler içerisinde bina olarak işaretlenmeyen ancak bina çıkıntıları, balkonlar gibi çeşitli nedenlerle görüntüler üzerinde bina olarak sınıflandırılması gereken alanları doğru sınıflandırmak için K-Ortalamalar yöntemi ile kontrolsüz olarak üretilen bina sınıfı bandı türetilmiştir.

Önerilen metotta geliştirilen ön işlem adımlarının ardından derin öğrenme algoritması olarak U-Net algoritması tercih edilmiştir. Önceki çalışmalar incelendiğinde U-Net algoritması ile semantik sınıflandırma yapılan çalışmalarda yüksek doğruluk elde edildiği görülmüştür. Geleneksel derin öğrenme algoritmalarının yanında U-Net algoritmasında tam bağlı katman bulunmamaktadır.

Konvölüsyon katmanlarından geçen görüntülerin semantik sınıflandırma sonuçlarının, geleneksel metotlar ile karşılaştırılması sonucunda yüksek doğruluk oranına sahip olduğu görülmüştür.

Tüm bandların ortak kullanımı ile geliştirilen model, eğitim süreci boyunca izlenmiş ve literatür taramaları sonucunda gereken matematiksel doğrulama modelleriyle birlikte performans ölçümü yapılmıştır.

Gerekli performans ölçümü, veri setinin %20'lik bir oranını kapsayan validasyon veri seti ile gerçekleştirilmiştir. Model eğitimi sonucunda model doğruluğu %81 olarak hesaplanmıştır. Ayrıca model performansını ölçen kayıp log kaybı değeri 0.4 olarak hesaplanmıştır. Sıfıra yakın fakat sıfıra eşit olmayan bu değer modelin yüksek doğrulukta eğitildiğini ve eğitim veri setini ezberlemediğini göstermektedir. X band SAR görüntüleri üzerinde eğitilen veri seti, farklı çalışma bölgesinden üretilen C band SAR görüntüleri üzerinde test edilmiş ve sonuçlar değerlendirilmiştir. Beklendiği gibi bina tespiti doğruluğunda bir düşüş gözlemlenmiş olup sınıflandırılmış görüntüde daha fazla gürültü meydana gelmiştir. Ayrıca bitki gruplarının hatalı sınıflandırma oranında artış gözlemlenmiştir.

Sunulan tez çalışması ile U-Net derin öğrenme algoritması, SAR görüntüleri üzerinde bina tespiti yapılması amacıyla ilk kez uygulanmıştır. Geliştirilen ön işlem adımları içerisinde ayrıca iki adet veri seti türetilmiştir. Geliştirilen model farklı bandlar ile üretilen SAR görüntüleri üzerinde test edilmiştir.

Rotterdam veri seti üzerinde eğitilmiş olan model her ne kadar İzmir veri seti üzerine uygulanabilir olmuş olsa da bina tespit doğruluğu düşük kalmaktadır. Bunun sonucunda farklı modeller üretme gerekliliği ortaya çıkmaktadır. Bu sayede her veri seti için ideal doğrulukta bina tespiti yapılabilecektir.

Eğitim için kullanılan görüntü sayısı artırılarak daha fazla görüntü ile eğitim gerçekleştirilecektir. Bu sayede daha yüksek doğrulukta modellerin elde edilmesi ön görülmektedir.

Sınıflandırılmış görüntüler üzerinde herhangi bir matematiksel işlem yapılmamış olup sonuçlar olduğu gibi paylaşılmıştır. Bu kapsamda gerekli matematiksel morfolojik işlemler kullanılıp sınıflandırılmış görüntüler manipüle edilerek sınıflandırma doğruluğunda artışa gidilmeye çalışılacaktır.

Bina alanlarının tespiti için kullanılan K-Means yönteminin yanı sıra son yıllarda tercih edilmeye başlanana normalize edilmiş bina indeksi (NDBI) test edilecektir.

Evrişim için kullanılan keskinleştirme kernelinin yanı sıra farklı amaçlar için kullanılan kerneller ile model eğitilecek ve sonuçlar gözlenecektir. Daha büyük boyutlardaki kernellerde ayrıca test edilecektir.



6. KAYNAKLAR

- Adamo, F., Brunner, D. and Bruzzone, L. 2010. Building detection and radar footprint reconstruction from single VHR SAR images. IEEE International Geoscience and Remote Sensing Symposium, pp. 292-295, 25-30 July, Honolulu, USA.
- Alshaikhli, T., Liu, W. and Maruyama, Y. 2019. Automated method of road extraction from aerial images using a Deep convolutional neural network. *Applied science*, 9(22): 4825.
- AMS. 2021. Radar frequency band https://glossary.ametsoc.org/wiki/Radar_frequency_band [Son erişim tarihi:07.02.2022]
- Aşçı, E. 2021. Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamasıyla Çocuklardan Alınan Panoramik Radyografilerde Çürük Dişlerin Tespiti. Uzmanlık Tezi, Atatürk Üniversitesi, Erzurum, 100 s.
- Arnault, C. 2020. Evrimsel sinir ağları. <https://www.sicara.ai/blog/2019-10-31convolutional-layer-convolution-kernel> [Son erişim tarihi:02.11.2021]
- Ayvaz, U. ve Çoban, A. 2016. Python Dilinin Öznitelikleri, Programlama Eğitiminde ve Yazılım Dünyasındaki Yeri. Akademik Bilişim Konferansı, ss. 6-6, 3-5 Şubat, Adnan Menderes Üniversitesi, Aydın.
- Balaji, S. 2021. Overfitting hakkında. <https://medium.com/@cs.sabaribalaji/overfitting-6c1cd9af589> [Son erişim tarihi:01.11.2021]
- Bozkurt, E. 2022. İzmir bitki örtüsü. <https://www.bitkiortusu.gen.tr/izmir-bitki-ortusu.html> [Son erişim tarihi:17.01.2022]
- Charvat, G., Fenn, A.J. and Perry, B.T. 2012. The MIT IAP radar course: Build a small radar system capable of sensing range, Doppler, and synthetic aperture (SAR) imaging, pp. 138-144, 7-11 May, Atlanta, USA.
- Chazareix, A. 2022. Kernel hakkında. <https://www.sicara.ai/blog/2019-10-31-convolutional-layer-convolution-kernel> [Son erişim tarihi:09.12.2021]
- Chen, S. and Wang, H. 2014. SAR target recognition based on deep learning. 2014. International Conference on Data Science and Advanced Analytics. 30 Oct.-1 Nov, Shanghai, China.
- Delibaşoğlu, İ. 2020. U-net tabanlı evrimsel sinir ağı ile uzaktan algılanmış görüntülerden otomatik bina tespiti. Doktora tezi, Yalova Üniversitesi, Yalova, 152 s.

- Dhaya, R. 2021. Hybrid Machine Learning Approach to Detect the Changes in SAR Images for Salvation of Spectral Constriction Problem. *Journal of Innovative Image Processing*, 3(2): 118-130.
- Deng, Z., Sun, H., Zhou, S., Zhao, J., Lei, L. and Zou, H. 2018. Multi-scale object detection in remote sensing imagery with convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145: 3-22.
- Eliçalışkan, M. 2021. Hollanda'nın Rotterdam bölgesine ait coğrafi bilgileri. <https://www.cografya.gen.tr/siyasi/devletler/hollanda.htm> [Son erişim tarihi: 27.12.2021].
- Gavankar, L. and Ghosh, K. 2019. Object based building footprint detection from high resolution multispectral satellite image using K-means clustering algorithm and shape parameters. *Geocarto International*, 34(6): 626-643.
- GDAL. 2021. GDAL anasayfası. <https://gdal.org/> [Son erişim tarihi:13.12.2021]
- Geojson Community. 2021. About geojson library. <https://pypi.org/project/geojson/> [Son erişim tarihi:13.12.2021]
- Ghaffarian, S., Valente, J., Voort, M. and Tekinererdogan, B. 2021. Effect of Attention Mechanism in Deep Learning-Based Remote Sensing Image Processing: A Systematic Literature Review. *Remote Sensing*. 13(15): 2965.
- GOC. 2021. Electromagnetic radiation. <https://www.nrcan.gc.ca/maps-tools-publications/satellite-imagery-air-photos/remote-sensing-tutorials/introduction/electromagnetic-radiation/14621> [Son erişim tarihi:05.02.2022]
- Google. 2022. About Tensorflow. <https://www.tensorflow.org/> [Son erişim tarihi:05.02.2022]
- Goodfellow, B. 2016. MIT press. <http://www.deeplearningbook.org/> [Son erişim tarihi:01.01.2022]
- Hasan, A. 2020. Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Borsa Alım Satım Davranışlarının Modellenmesi. Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul, 107 s.
- Hoeser, T., Bachofer, F. and Kuenzer, C. 2020. Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review—Part II: Applications. *Remote Sensing*, 12(18): 3053.

- Hoeser, T. and Kuenzer, C. 2020. Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends. *Remote Sensing*, 12(10): 1667.
- İnik, Ö. ve Ülker, E. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpasa Bilimsel Araştırma Dergisi*, 6(3): 85-104.
- Kang, M., Leng, X., Lin, Z. and Ji, K. 2017. A modified faster R-CNN based on CFAR algorithm for SAR ship detection. *International Workshop on Remote Sensing with Intelligent Processing*, 1-4.
- Kaynarca, M. and Demir, N. 2018. Detection of Urban Buildings by Using Multispectral Gokturk-2 and Sentinel 1A Synthetic Aperture Radar Images. *MDPI Proceedings*, 2(7): 360.
- Keras Community. 2022. About Keras. <https://keras.io/> [Son erişim tarihi:07.02.2022]
- Kızrak, A. 2021. U-Net algoritması. <https://ayyucekizrak.medium.com/g%C3%B6r%C3%BCnt%C3%BCn%C3%B6l%C3%BCtleme-segmentasyon-i%C3%A7in-derin-%C3%B6l%C4%9Frenme-u-net-3340be23096b> [Son erişim tarihi:05.02.2022]
- Lee, J. H., Han, S. S., Kim, Y. H., Lee, C. and Kim, I. 2020. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral surgery, oral medicine, oral pathology and oral radiology*, 129(6): 635-642.
- Liu, P., Di, L., Du, Q. and Wang, L. 2018. Remote Sensing Big Data: Theory, Methods and Applications. *Remote Sensing*, 10(5): 711.
- Long, J., Shelhamer, E. and Darrell, T. 2015. Fully Convolutional Networks for Semantic Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3431-3440.
- Marin, C., Bovolo, F. and Bruzzone, L. 2014. Building Change Detection in Multitemporal Very High Resolution SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5): 2664-2682.
- MGM. 2021. İzmir hava koşulları bilgisi. <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=IZMIR> [Son erişim tarihi:11.12.2021]
- Mehra, A., Jain, N. and Srivastava, H. 2019. A novel approach to use semantic segmentation based deep learning networks to classify multi-temporal SAR data. *Geocarto International*, 37(1): 163-178.

- NumPy Community. 2022. About NumPy. <https://numpy.org/> [Son erişim tarihi: 05.02.2022]
- Osmanoğlu, U. 2021. Makine Öğrenmesi Sınıflama Algoritmalarıyla Kalp Yetersizliği Mortalitesinin Tahminlenmesi. Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Eskişehir, 75 s.
- Papson S. and Narayanan, R. 2012. Classification via the Shadow Region in SAR Imagery. *IEEE Transactions on Aerospace and Electronic Systems*, 48(2): 969-980.
- Pi, Y., Nath, N. and Behzadan, A. 2020. Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. *Advanced Engineering Informatics*, 43: 101009.
- Ronneberger, O., Fischer, P. and Brox, T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation, Medical Image Computing and Computer-Assisted Intervention, pp. 234-241, 5-9 October, Munich, Germany.
- Santra, A. K., Christy, J. C. 2012. Genetic Algorithm And Confusion Matrix For Document Clustering. *International Journal of Computer Science Issues*, 9(1): 322.
- Scikit Image Community. 2022. About Scikit Image. <https://scikit-image.org/> [Son erişim tarihi:19.01.2022]
- Sommer, L., Schuchert, T. and Beyerer J. 2017. Deep learning based multi-category object detection in aerial images. Automatic Target Recognition XXVII, pp. 48-55, 1 May, Anaheim, California, United States.
- SpaceNet. 2020. SpaceNet - 6 Multi Sensor All- Weather Mapping challenge. <https://www.topcoder.com/challenges/ad4caf4a-f7c9-4330-a5c2-56c7125b554f> [Son erişim tarihi:05.02.2022]
- Sun, L. Wu, T., Feng, D. and Tong, L. 2020. Object Detection Research of SAR Image Using Improved Faster Region-Based Convolutional Neural Network. *Journal of Geodesy and Geoinformation Science*, 3(3): 18.
- Öçer, E. 2020. Uzaktan algılama görüntülerinde derin öğrenme temelli yaklaşımlar kullanarak nesne tespiti. Doktora Tezi, Eskişehir Teknik Üniversitesi, Eskişehir, 109 s.
- Taff, W. 2018. Object Detection and Digitization from Aerial Imagery Using Neural Networks . Master Thesis, University of Southern California, 113 p.

- Vakalopoulou, M., Karantzas, K., Komodakis N. and Paragios, N. 2015. Building detection in very high resolution multispectral data with deep learning features. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1873-1876.
- Vovk, V. 2015. The fundamental nature of the log loss function. *Fields of Logic and Computation II*, 307-318.
- Waldner, F. and Diakogiannis, F. 2020. Deep learning on edge: extracting field boundaries from satellite images with a convolutional neural network. *Remote Sensing of Environment*, 245: 111741.
- Wall, D., Herman, P. and Wielemaker, A. 2005. Characterisation of surface roughness and sediment texture of intertidal flats using ERS SAR imagery. *Remote Sensing of Environment*, 98(1): 96-109.
- Weather Spark. 2021. Rotterdam hava koşulları bilgisi. Weather Spark. 2021. Rotterdam hava koşulları bilgisi. <https://tr.weatherspark.com/y/51258/Rotterdam-Hollanda-Ortalama-Hava-Durumu-Y%C4%B1l-Boyunca> [Son erişim tarihi:11.12.2021]
- Wilmanski, M., Kreucher, C. and Lauer J. 2016. Modern approaches in deep learning for SAR ATR. *Algorithms for Synthetic Aperture Radar Imagery XXIII*. 9843: 195-204.
- Wu, Z. and Hou, B. 2021. A Deep Detection Network Based on Interaction of Instance Segmentation and Object Detection for SAR Images. *Remote Sensing*. 13(13): 2582.
- Xu, Y., Wu, L., Xie, Z. and Chen, Z. 2018. Building Extraction in Very High Resolution Remote Sensing Imagery Using Deep Learning and Guided Filters. *Remote Sensing*, 10(1): 144.
- Xu, Z., Wang, R., Zhang, H. and Li, Z. 2017. Building extraction from high-resolution SAR imagery based on deep neural networks. *Remote Sensing Letters*, 8(9): 888-896.
- Zhang, J. 2022. Python'da U-Net uygulamaları. <https://towardsdatascience.com/unet-line-by-line-explanation-9b191c76baf5> [Son erişim tarihi:21.01.2022]
- Zhao, X., Yuan, Y., Song, M., Ding, Y., Lin, F., Liang, D. and Zhang, D. 2019. Use of unmanned aerial vehicle imagery and Deep Learning Unet to extract rice lodging. *sensors*, 19(18): 3859.

- Zhong, Y., Han, X. and Zhang, L. 2018. Multi-class geospatial object detection based on a position-sensitive balancing framework for high spatial resolution remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 138: 281-294.
- Zhu, X., Montazeri, S., Ali, M., Hua, Y., Wang, Y., Mou, L., Shi, Y., Xu, F. and Bamler, F. 2021. Deep Learning Meets SAR. *IEEE Geoscience and Remote Sensing Magazine*. 9(4): 143-172.
- Zhu, X., Tuia, D., Mou, L., Xia, G. and Zhang, L. 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4): 8-36.



ÖZGEÇMİŞ

Recai Alper EMEK

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2019-2022	Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı, Antalya
Lisans	Yıldız Teknik Üniversitesi
2013-2018	İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul

ESERLER

Uluslararası hakemli dergilerde yayımlanan makaleler

1- Emek, A., Demir, N. (2020). Building Detection From Sar Images Using Unet Deep Learning Method. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIV-4/W3-2020, 215–218. Doi:10.5194/isprs-archives-XLIV-4-W3-2020-215-2020

Ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1- Emek, A., Kılıç, F. (2018). Görüntü Sınıflandırma Arayüzü: Python ve K-Ortalama Yöntemi. VII. Uzaktan Algılama ve Cbs Sempozyumu, 874-879. Doi: 10.15659/uzalcbs2018.6125