

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

SAR (SENTETİK AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDE BÖLÜTLEME

Hakan ERTEN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2021**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

SAR (SENTETİK AÇIKLIKLI RADAR) GÖRÜNTÜLERİNDE BÖLÜTLEME

Hakan ERTEN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç.Dr. Gazi Erkan BOSTANCI

Bu tez çalışması kapsamında amaçlanan SAR (Sentetik Açıklıklı Radar) görüntüleri ile yeni bir veri seti oluşturma aşamalarının detaylı olarak açıklanması, derin öğrenme modelleri ile bu yeni veri setinin nasıl kullanıldığının gösterilmesi ve kullanılan bu modellerin Mc Nemar's testi ile kıyaslanmasıdır. SAR görüntülerine ücretsiz ve kolay bir şekilde erişilebilse de, görüntülerdeki benek gürültüsü ve ücretsiz etiketlenmiş veri setinin olmamasından dolayı görüntü işlemede direkt olarak kullanılamamaktadır. Bu çalışmada, öncelikle bu gürültüler ortadan kaldırılmış, elde edilen görüntülerin bölütlemeye kullanılabilmesi için görüntüler etiketlenmiş ve bölütlemeye en başarılı sonuçlar veren derin öğrenme modelleri ile bu yeni veri seti denenmiştir. Toplamda 3 ayrı model kullanılmış olup, modellerden hangisinin daha başarılı olduğu Mc Nemar's testi ile kıyaslanmıştır. Sonuç olarak, kullanılan modellerden HRNet ile %92.23 toplam piksel doğruluğu (PA) ve mean Intersection over Union (mIoU) değeri %70.60 olarak elde edilmiştir. Ayrıca, benek gürültüsünün görüntü bölütlemesindeki etkisini göstermek amacıyla, benek gürültülü görüntüler ile gürültüsüz görüntüler karşılaştırılmış ve sonuçlar birbirleri ile kıyaslanmıştır.

Haziran 2021, 45 Sayfa

Anahtar Kelimeler: SAR, SAR Bölütlemesi, Sentinel-1, Semantik Bölütleme

ABSTRACT

Master Thesis

SAR (SYNTHETIC APERTURE RADAR) IMAGES SEGMENTATION

Hakan ERTEN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assoc. Prof. Dr. Gazi Erkan BOSTANCI

The aim of this thesis are to explain of the processes of creating a new data set with SAR (Synthetic Aperture Radar) images in detail, to demonstrate of how this new dataset is used with deep learning models and to compare of these models used with Mc Nemar's test. Although SAR images can be accessed freely and easily, these are not convenient to be used directly due to the speckle noise, and also there is almost no free available labeled dataset for scientific research. In this study, we propose a novel process that automatedly creates a dataset and removes the speckle noise, labeling images and using the automatedly-created dataset to enhance semantic segmentation task results with state of the art deep neural networks. Used 3 models are evaluated with Mc Nemar's test. As a result, we achieved an overall pixel accuracy (PA) of 92.23% and a mean Intersection over Union (mIoU) of 70.60%. Beside, to show the effectiveness of our noise removal process, we compare the results of models on speckled noise and noise-free versions of our newly-created dataset.

June 2021, 45 Pages

Keywords: SAR, SAR Segmentation, Sentinel-1, Semantic Segmentation

TEŐEKKÜR

H.Erten yüksek lisans süresinde 2210-A burs programıyla TÜBİTAK'tan destek almıştır. Yüksek lisans eğitimim sürecinde sabırla desteğini esirgemeyen eşim Ceren'e, bana hayat enerjisi veren kızım Duru'ya, çalışmam boyunca benden bir an olsun yardımlarını esirgemeyen ve gece gündüz destek olan arkadaşım Emre BORAN'a, çalışma süresince tüm zorlukları benimle birlikte göğüsleyen ve yardım eden arkadaşım Adnan Kutay YÜKSEL'e ve tez çalışmasının her aşamasında bana destek olup yol gösteren, mesleki bilgilerini ve deneyimlerini öğrencilerinden esirgemeyip önerileri ile katkıda bulunan değerli tez danışmanım Sayın Doç. Dr. Gazi Erkan BOSTANCI hocama sonsuz teşekkürlerimi sunarım.

Hakan ERTEN

Ankara, Haziran 2021

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
SİMGELER VE KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ.....	1
2. SAR VE SENTINEL-1 HAKKINDA GENEL BİLGİLER.....	3
2.1 Sentetik Açıklıklı Radar Hakkında Genel Bilgiler.....	3
2.2 Sentinel-1.....	7
2.3 CORINE Veri Seti.....	9
3. SAR GÖRÜNTÜ BÖLÜTLEMESİ.....	11
3.1 Konvolüsyonel Sinir Ağları.....	12
3.1.1 Konvolüsyon katmanı.....	12
3.1.2 Havuzlama katmanı.....	14
3.1.3 Tam bağlı katman.....	15
3.1.4 Kullanılan diğer önemli parametre ve fonksiyonlar.....	16
3.2 Literatür İncelemesi.....	16
3.2.1 Kullanılan veri setleri.....	16
3.2.2 Karşılaşılan ortak temel sorunlar.....	17
3.2.3 Literatür özeti.....	18
4. UYGULAMA	22
4.1 Genel Bakış.....	22
4.2 Veri Seti Oluşturma	23
4.3 Eğitim ve Materyaller.....	26
4.4 Modeller.....	27
4.4.1 U-Net.....	27
4.4.2 Pyramid Scene Separation Network (PSPNet).....	28
4.4.3 High-Resolution Network (HRNet).....	29
4.5 Mc Nemar's Testi.....	30

5. DEĞERLENDİRME.....	32
5.1 Bölütleme Performansları.....	32
5.2 Mc Nemar's Testi Sonuçları.....	35
6. SONUÇ	38
KAYNAKLAR.....	40
ÖZGEÇMİŞ.....	45



SİMGELER DİZİNİ

$\Delta c r$	Uçuş yönündeki yanca çözünürlük
Δr	Menzi yönündeki çözünürlük

Kısaltmalar

ASI	Adjacent Satellite Interference
CONAE	Comision Nacional de Actividades Espaciales
COSMO-SkyMed	Constellation of Small Satellites for Mediterranean Observation
CSA	Canadian Space Agency
DLR	German Aerospace Center
EEA	European Environment Agency
ESA	European Space Agency
FCN	Fully Convolutional Network
FN	False Negative
FP	False Positive
GRD	Ground
IoU	Intersection over Union
IW	Interferometric Wide Swath
JAXA	Japan Aerospace Exploration Agency
JPL	Jet Propulsion Laboratory
Komposat-5	Korean Multi-purpose Satellite 5
MA	Mean Accuracy
mIoU	Mean Intersection over Union
NASA	National Aeronautics and Space Administration
PA	Pixel Accuracy
SAR	Sythetic Aperture Radar – Sentetik Açıklıklı Radar
SEASAT	Seafaring Satellite
TP	True Positive

ŞEKİLLER DİZİNİ

Şekil 2.1. SAR çözünürlüğü.....	3
Şekil 2.2 Genel SAR sistem mimarisi.....	3
Şekil 2.3 SAR modlarının zemini tarama biçimleri	8
Şekil 2.4 CORINE arazi örtüsü örnek görüntü	10
Şekil 3.1 Bölütleme süreci.....	11
Şekil 3.2 CNN mimarisi.....	12
Şekil 3.3 Konvolüsyon işlemi	13
Şekil 3.4 Aktivasyon fonksiyonları	14
Şekil 3.5 Havuzlama örnekleri.....	15
Şekil 3.6 MSTAR SAR görüntü örneği.....	17
Şekil 4.1 Önerilen model.....	20
Şekil 4.2 Örnek RGB SAR görüntüleri.....	23
Şekil 4.3 U-Net mimarisi.....	25
Şekil 4.4 PSPNet mimarisi.....	26
Şekil 4.5 HRNet mimarisi.....	26
Şekil 5.1 HRNet modelinin uygulanması sonucu bazı örnekler.....	31

ÇİZELGELER DİZİNİ

Çizelge 2.1 Frekans bantları	4
Çizelge 2.2 SAR sensörleri tarihçesi.....	5
Çizelge 2.3 Sentinel-1 sistem parametreler.....	7
Çizelge 2.4 Sentinel-1 SAR görüntüleme modları temel parametreleri.....	8
Çizelge 4.1 Veri seti genel bilgileri.....	21
Çizelge 4.2 z değerine bağlı güven parametreleri.....	27
Çizelge 5.1 U-Net modeli bölütleme sonuçları.....	29
Çizelge 5.2 PSPNet modeli bölütleme sonuçları.....	29
Çizelge 5.3 HRNet modeli bölütleme sonuçları.....	30
Çizelge 5.4 mIoU, MA ve PA değerleri karşılaştırma çizelgesi.....	30
Çizelge 5.5 Her bir test görüntüsü için modellerin PA değerleri ve kıyas örnekleri.....	32
Çizelge 5.6 Tüm modeller için uygulanan Mc Nemar's testi sonuçları.....	34

1. GİRİŞ

SAR (Sentetik Açıklı Radar – Sythetic Aperture Radar) insanlı/insansız hava araçları ya da uydularda kullanılabilen, gece/gündüz her türlü hava koşulunda (yağışlı/bulutlu dahil) yüksek çözünürlüklü görüntüleme ve hedef tespiti yapabilen bir radar sistemidir. SAR temel olarak mikrodalga sinyallerini yeryüzüne ileten ve Dünya yüzeyinden geri dönen veya saçılan sinyalleri geri toplayan aktif bir sensördür. Aktif bir sensör olması enerjisini kendi üretmesi ve bu sayede sinyalleri geri toplamasını sağlamaktadır. Sentetik açıklık kavramı ise hava ya da uydu platformunun uçuş boyunca sinyalleri toplayarak işlemesidir. Elde edilen veri uçuş sürecinde elde edildiği için yüksek çözünürlüklü görüntüler oluşturulabilmektedir (Curlander ve McDonough 1991). Yüksek çözünürlüklü görüntüler ve gece/gündüz her türlü hava koşulunda çalışabilmesi sayesinde çok geniş bir kullanım alanı vardır. Hedef tespiti, yeryüzü görüntüleme, tarımsal alanların değerlendirilmesi, orman alanların değişimi, buzulların kontrolü vb. değişik alanlarda bir çok bilim dalında kullanılabilir.

SAR, Carly Wiley tarafından Goodyear Aircraft şirketinde 1951’de bir program üzerine çalışma yaparken bulunmuştur (Wiley 1985). NASA 1960’lı yıllarda SAR’ın gelişimine ve çalışmalarına destek vermeye başlamıştır. İlk sivil SAR uydusu SEASAT 1978 yılında uygulamaya alınmıştır (Wikipedia 2020). Teknolojinin gelişmesi ile beraber SAR çok çeşitli hava ve uydu platformlarıyla kullanılmaya başlamış ve değişim hızla artmıştır. Günümüzde değişik bantlarda, sensorlerle çalışan bir çok çeşit SAR uydusu bulunmaktadır.

SAR, hızlı ve kesin görüntü işleme (Ding vd. 2014), hedef tespiti, dünyanın görüntülenmesi, tarım alanlarının, buzulların ve ormanları kontrolü gibi bir çok alanda geniş kullanım yelpazesi sunmaktadır. SAR görüntülerinin bir çok alanda kullanılmasına ve gelişen teknolojilerle kalitesini artırmasına rağmen, uydu platformlarından elde edilen SAR görüntülerinin işlenmesi ve kıymetlendirilmesi konusunda büyük bir eksiklik bulunmaktadır. Hava araçları ile tespit edilen görüntüler daha çok askeri ya da spesifik amaçlara hizmet eden alanlarda kullanılmakta olup, kısıtlı açık kaynak veri setleri ile de alanda bir çok çalışma yapılmıştır. Uydu platformlarından elde edilebilecek açık kaynak veri setleri çok olmasına rağmen etiketlenmiş veri seti bulmak hala çok büyük bir sorun

teşkil etmektedir. Ayrıca elde edilen görüntüler de benek gürültüsü olduğu için görüntülere ön işleme yapılmadan görüntü işleme için kullanılamamaktadır. Bu sebepten dolayı uydu platformlarından elde edilen SAR görüntülerinin bölütlemesinde henüz başarılı sonuçlar elde edilememiştir. Bu nedenle, bu çalışmamın amacı Avrupa Uzay Ajansının (ESA) ücretsiz kullanıma sunduğu Sentinel-1 görüntülerinden elde edilen SAR görüntülerini ön işleme yaparak gürültüsünü yok etmek, görüntüleri etiketleyerek veri seti elde etmek ve elde edilen bu veri seti ile derin öğrenme modellerini kullanarak SAR görüntülerini bölütlemektir. Bu sayede yeni bir veri setinin nasıl elde edilebileceği ve bölütleme metodlarının kullanımı, birbirleriyle karşılaştırılması detaylı anlatılmaya çalışılmıştır. Kullanılan derin öğrenme modelleri Mc Nemar's testi ile kıyaslanarak hangi modelin daha başarılı sonuçlar verdiği açıklanmıştır.

Bu çalışma ile Sentinel-1 SAR görüntüsünden yeni veri seti oluşturulması ve derin öğrenme modellerin uygulanması hedeflenmiştir. Özet olarak bu tezin katkıları;


- 1) Yeni bir veri seti oluşturma için süreç ortaya konmuştur.
- 2) En yüksek başarı elde edilen ve son dönemlerde en çok kullanılan derin öğrenme modelleri kullanılarak karşılaştırma yapılmıştır.
- 3) Derin öğrenme modelleri ile sonuçlar kıyaslanırken benek gürültülü görüntüler ile gürültüsüz görüntüler kıyaslanmaktadır.
- 4) Mc Nemar's testi ile kullanılan modellerin performansları kıyaslanacaktır.

2. SAR VE SENTİNEL-1 HAKKINDA GENEL BİLGİLER

Bu bölümde öncelikle SAR hakkında temel bilgiler verilecek, sonra veri setinde kullanılan ve ESA'nın ücretsiz kullanıma sunduğu Sentinel-1 (SAR) açıklanacak ve SAR görüntülerinde bölütleme hakkında detaylı bilgiler verilecektir.


2.1 Sentetik Açıklık Radar Hakkında Genel Bilgiler

SAR, radyo dalgalarının kullanılarak görüntü oluşturulma yöntemidir. Radarın hareketli olması sebebiyle belirli aralıklarla ölçüm değerleri alınarak ve bu değerler aynı anda toplanarak sentetik açıklık meydana geldiğinde, büyük bir yapay açıklık oluşacaktır (Soumekh 1999). Oluşan yapay açıklık büyük bir fiziksel anten, yüksek çözünürlüklü görüntüler elde edilmesini sağlayacaktır.



Şekil 2.1 SAR çözünürlüğü (O'Donnell 2009)

Şekil 2.1'de SAR görüntülerinde çözünürlüğün nasıl hesaplandığı gösterilmiştir. Hesaplardan da anlaşılacağı gibi yüksek çözünürlüklü görüntü elde edebilmek için büyük antenlere ihtiyaç bulunmaktadır.



Şekil 2.2 Genel SAR sistem mimarisi (Irak 2009)

Şekil 2.2’de SAR sisteminin genel mimarisi ortaya konmuştur. SAR sensörü tarafından elde edilen ham veri işlenerek, görüntü değerlendirme biriminde artık hedefin tespiti ve sınıflandırması ile kullanıcıya aktarılması süreci gösterilmiştir. Her birim kendi isminden anlaşılacağı işlemleri yerine getirmektedir.

SAR görüntüleri çok sayıda bilimsel disiplinin ayrılmaz bir parçası haline gelmiştir. SAR'ın çeşitli uygulamalardaki kullanımları aşağıda listelenmiştir: (Martin 2004)

- a) Deniz ve buzul görüntüleme
- b) Petrol kirliliği ve çevre izleme
- c) Gemi izleme ve gözetleme
- d) Kar ve deniz buzu izleme
- e) Toprak arazisinin sınıflandırılması
- f) Dalga spektrumları ve önemli dalga yüksekliği ölçümleri

SAR görüntülerinin elde edildiği bir çok farklı frekansta çalışan bantlar bulunmaktadır. Bu bantlar Çizelge 2.1’de verilmiştir.

Çizelge 2.1 Frekans bantları (Yumus 2019)

Bantlar	Frekans (GHz)
L	1 - 2
S	2 - 4
C	4 - 8
X	8 - 12
Ku	12 - 18
K	18 - 27
Ka	27 - 40
V	40 - 75
W	75 - 110
MM	110 - 300

SAR sensörlerinin tarihsel süreci kısaca çizelge 2.2’de gösterilmektedir (Yumus 2019).

Çizelge 2.2 SAR sensörleri tarihçesi

Uydu	Polarizasyon Türü	Frekans Bandı	Açıklamalar
SEASAT	YY	L	1978 yılında NASA tarafından gönderilen ilk sivil SAR uydusu
ERS-1/2	DD	C	1991-2000/1995-2011 yılları arasında çalışan ESA tarafından gönderilen ilk Avrupa SAR uydusu
J-ERS-1	YY	L	1992-1998 yılları arasında JAXA tarafından gönderilen ilk Japon SAR uydusu
SIR-C/ X-SAR	Dörtlü DD	L & C X	Nisan ve Kasım 1994 yılında Amerika, Almanya ve İtalya tarafından çoklu frekanslar ilk gösterimi
RADARSAT-1	YY	C	1995 yılında Kanada (CSA) tarafından gönderilen ilk Kanada SAR uydusu
SRTM	YY+DD DD	C X	2000 yılında Amerika, Almanya ve İtalya tarafından gönderilen ve uzayda bulunan ilk interferometrik
ENVISAT/ ASAR	Çift Polarizasyon	C	ESA tarafından 2000-2012 yılları arasında çalışan gönderme / alma modülü teknolojisi sahip ilk SAR uydusu
ALOS/ PalSAR	Dörtlü Polarizasyon	L	JAXA (Japonya) tarafından 2006-2011 arasında yönetilen Gelişmiş Arazi Gözlem Uydusu
TerraSAR-X/ TanDEM-X	Dörtlü Polarizasyon	X	DLR/Astrium (Almanya) tarafından 2007 ve 2010 yıllarında başlayan uzaydaki ilk iki statik radar
SAOCOM-1/2	Dörtlü Polarizasyon	L	CONAE (Arjanti) tarafından 2014/2015’te başlatılan tamamen polarimetrik iki uydu takım yıldızı
RADARSAR Takımyıldız- 1/2/3	Dörtlü Polarizasyon	C	CSA (Kanada) tarafından 2017 yılında başlatılan ve üç uydu oluşan takımyıldızı

Çizelge 2.2 SAR sensörleri tarihçesi (Devam)

RADARSAT-2	Dörtlü Polarizasyon	C	CSA (Kanada) tarafından 2007 yılından itibaren yönetilmekte ve Çözünürlük: 1 m x 3 m (yanca x menzil), Şerit genişliği: 500 km
COSMO-SkyMed-1/4	Çift Polarizasyon	X	ASI/MID (İtalya) tarafından yönetilen dört uydu takım yıldızı
RISAT-1	Dörtlü Polarizasyon	C	ISRO (Hindistan) tarafından 2016 yılında piyasaya sürülen uydu (RISAT-1a), geliştirilmekte olan RISAT-3 (L-band)
HJ-1C	DD	S	CRESDA/ CAST/ NRSCC (Çin) tarafından dört uydu takımıydı, ilk uydu 2012'de başlatıldı.
KOMPOSAT-5	Çift Polarizasyon	X	KARI (Kore) tarafından 2013'te başlatılan çok amaçlı uydu 5, 1 m'ye kadar çözünürlük
PAZ	Dörtlü Polarizasyon	X	CDTI (İspanya) tarafından 2013 yılında başlatılan TerraSARX, TanDEM-X ile takımıydı
ALOS-2	Dörtlü Polarizasyon	L	JAXA (Japonya) tarafından 2013 yılından başlatılan ve Çözünürlük: 1 m # 3 m (yanca # menzil), şerit genişliği: 490 km
SENTINEL-1A/1B	Dörtlü Polarizasyon	C	ESA tarafından 2013 ve 2015 yıllarında başlatılan ve detayları aşağıda anlatılan, iki uydudan oluşan takım yıldızı, şerit

2.2 Sentinel-1

Sentinel, Avrupa Uzay Ajansı (ESA) tarafından işletilen Kopernik adlı programın adıdır. Sentinel-1 aynı yörüngeyi paylaşan 2 uydudan (Sentinel-1A ve Sentinel 1-B) oluşmakta olup programın ilk uydu kümesidir. Sentinel-1A 3 Nisan 2014 tarihinde , Sentinel-1B ise 25 Nisan 2016'da uzaya fırlatılmıştır.

Sentinel-1, her türlü hava şartında, 24 saat esasına göre veri elde eden, C-bantlı ve sentetik açıklıklı bir radar taşımaktadır (Anonymous 2020).

Sentinel-1'e ait temel parametreler Çizelge 2-3'de gösterilmiştir.

Çizelge 2.3 Sentinel-1 sistem parametreleri (Bourbigot 2016)

Parametre	Değer
Bakış Yönü	Sağ
Radar Taşıyıcı Frekans	5.405 GHz
Radyo Frekans Tepe Gücü	4.141 kW
Anten Uzunluğu	12.3 m
Pals Tekrarlama Frekans Değerleri	1000 Hz – 3000 Hz
Polarizasyon Çeşitleri	YY,DD (Tek) ve YY+YD, DD+DY (Çift)
Anten Kiriş Genişliği	0.23°
Anten Genişliği	0.82 m
Yükseklik Kiriş Genişliği	3.43°
Yükseklik Kiriş Direksiyon Menzili	[-13.0°, +12.3°]

Sentinel-1 veri toplamayı 4 farklı modda yapılmaktadır. Bu modlar; (Anonymous 2020)

1. Stripmap (SM) modu: 80 km'lik bir şerit şeridiyle verileri 5 m'ye 5 m uzamsal çözünürlükten biraz daha iyi bir şekilde alır. Anten ışını sabit bir azimut açısına ve yaklaşık olarak sabit bir uzak en düşük açısına işaret ederken (bu, dönüş yönünden dolayı küçük değişikliklere tabidir), zemin alanı sürekli bir darbe dizisi ile aydınlatılır. SM görüntüleri, yaklaşık olarak sabit bir geliş açısında sürekli iz görüntü kalitesine sahiptir.

2. İnterferometrik Geniş (IW) şerit modu: Arazi üzerinde ana görüntü edinim modudur ve hizmet gereksinimlerinin çoğunu karşılamaktadır. 5 m'ye 20 m uzamsal çözünürlükte

(tek bakışta) 250 km'lik bir şeritle veri alır. IW modu, Aşamalı Taramalar SAR ile Arazi Gözlemine kullanarak üç alt şeridi yakalamaktadır (TOPSAR).

3. Ekstra Geniş (EW) şerit modu: IW moduna benzer şekilde, beş alt şerit kullanan IW modundan daha geniş bir alanda veri elde etmek için TOPSAR tekniğini kullanmaktadır. EW modu, 20 m'ye 40 m uzamsal çözünürlükte 400 km'lik bir şerit üzerinde veri toplamaktadır.

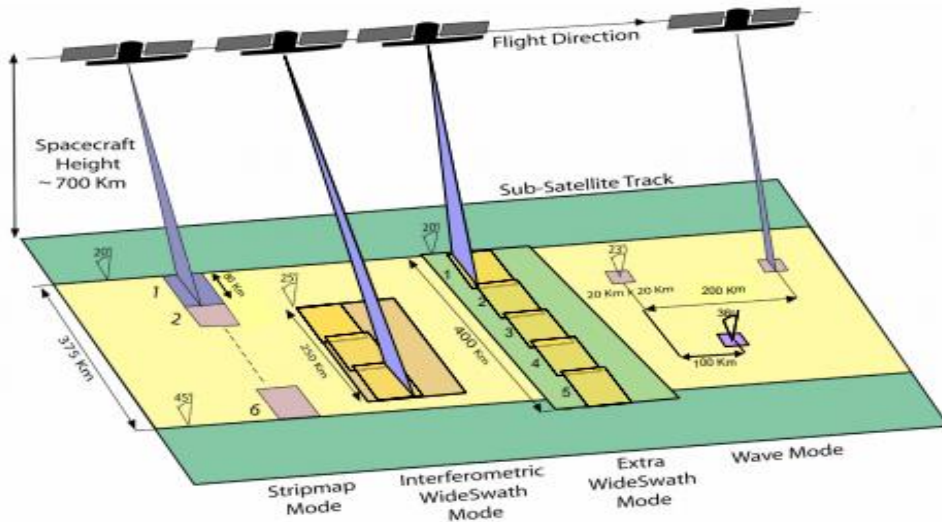
4. Wave (WV) Modu: Bu modda şerit haritası görüntüsü, yörünge boyunca her 100 km'de bir 20'ye 20 km'lik parçalar elde etmek için sabit bir açık / kapalı görev döngüsünde değişen yükseklik ışınları kullanılarak çekilmektedir.

SAR radarının modlarının temel parametreleri Çizelge 2.4'de belirtilmiştir.

Çizelge 2.4 Sentinel-1 SAR görüntüleme modları temel parametreleri (Dirk vd. 2014)

Mod	Geliş Açısı (Derece)	Bant Genişliği (Hz)	Çözünürlüğü (m)
SM	20-43	87.6-42.2	5 x 5
IW	30-42	56.5-42.8	5 x 20
EW	20-44	22.2-10.4	20 x 40
WV	23 & 36.5	74.5 & 48.2	5 x 5

Yukarıda anlatılan modlara göre sensörün tarama biçimleri Şekil 2.3'de gösterilmiştir.



Şekil 2.3 SAR modlarının zemini tarama biçimleri (Bourbigot 2016)

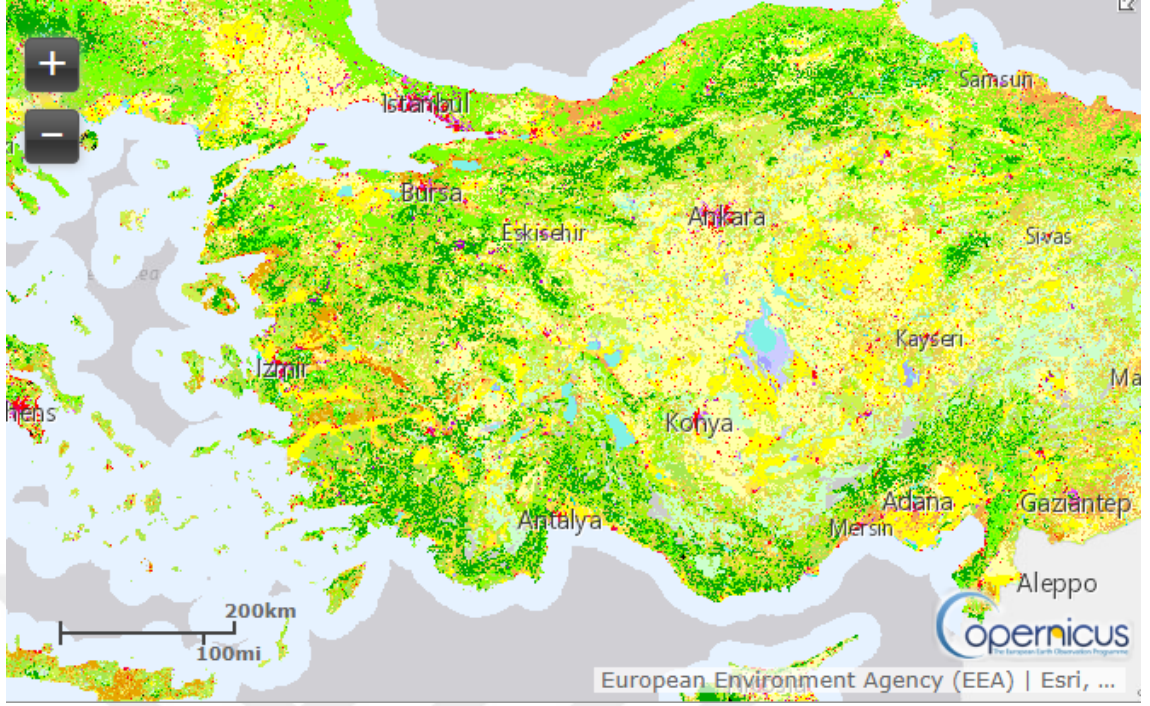
Hava araçları ve uydu platformlarıyla elde edilen görüntüler teknolojinin hızla gelişmesiyle birlikte kalite ve sayı olarak artmıştır. Bu sebeple bu konuda yapılan çalışmalar ve görüntünün işlenmesi gün geçtikçe önem kazanmaktadır. Bu alanda yapılan çalışmalar ise henüz yüksek başarıya ulaşamamıştır. Çünkü SAR imgelerinin işlenmesi, kıymetlendirilmesi ve çok sayıda etiketli SAR görüntüsünü elde edilmesi çok zorlu bir süreçtir.

Bu nedenlerden dolayı alan çalışmasının çok büyük bir bölümü gözetimsiz öğrenme algoritmalarını kullanmış ve sonuçlar belli bir başarı düzeyinde kalmıştır. Yapılan bu çalışma ile etiketlenmiş veri setinin elde edilme aşamaları detaylı olarak açıklanacak, gözetimli öğrenme metotları ile daha yüksek başarılar elde edilmeye çalışılacaktır.

2.3 CORINE Veri Seti

CORINE arazi örtüsü Avrupa Çevre Ajansı (EEA) tarafından koordine edilen tutarlı bir Pan-Avrupa arazi örtüsü haritalama girişiminin çok önemli örneklerinden biridir (Büttner vd. 2004) (Bossard vd. 2000) . CORINE, çevreyle ilgili bilgilerin koordinasyonu anlamına gelmektedir. Bu çalışma uzun vadeli uygulanması hedeflenmekte ve Avrupa'nın sınıflandırma arazisi için 4 yılda bir güncellenmektedir (Šćepanović vd. 2021). CORINE haritaları Avrupa'daki çeşitli müşteri grupları için de operasyonel amaçlara uygun önemli bir arazi örtüsü bilgisi kaynağı sağlamaktadır. Toplamda 44 sınıfa sahip olmakla birlikte, bu sınıflar arazi kullanım sınıflarıdır.

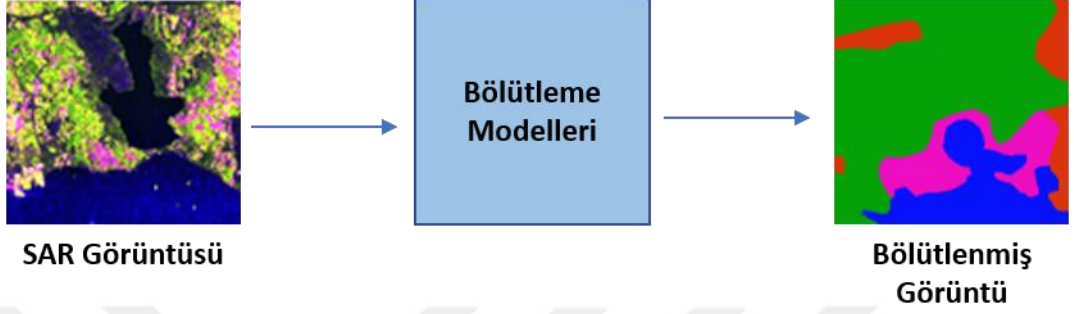
CORINE çerçevesindeki ulusal arazi örtüsü haritaları, daha küçük haritalama birimleri sergilemektedir. Bu çalışmada, 44 sınıflı CORINE veri seti 5 sınıfa indirilmiş ve 5 sınıfla kullanılmıştır. CORINE arazi örtüsü kendi sayfasındaki 2018 bu çalışma için kullanılmıştır ve bu veri seti ücretsiz elde edilebilmektedir (Corine Land Cover 2020). Bu çalışmada kullanılan CORINE veri setine ait örnek görüntü Şekil 2.4'de gösterilmiştir.



Şekil 2.4 CORINE arazi örtüsü örnek görüntü (Corine Land Cover 2020)

3. SAR GÖRÜNTÜ BÖLÜTLEMESİ

SAR Görüntü bölütlemesinde amaç; SAR görüntülerinde farklı özelliklere sahip anlamı bölgelerin yüksek doğrulukla birbirinden ayrılmasıdır (Jiao vd. 2010). Bölütleme süreci temel olarak Şekil 3.1’de gösterilmiştir.



Şekil 3.1 Bölütleme süreci

Hava araçları ve uydu platformlarıyla elde edilen görüntüler teknolojinin hızla gelişmesiyle birlikte kalite ve sayı olarak artmıştır. Bu sebeple bu konuda yapılan çalışmalar ve görüntünün işlenmesi gün geçtikçe önem kazanmaktadır. Bu alanda yapılan çalışmalar ise henüz yüksek başarıya ulaşamamıştır. Çünkü SAR imgelerinin işlenmesi, kıymetlendirilmesi ve çok sayıda etiketli SAR görüntüsünü elde edilmesi çok zorlu bir süreçtir.

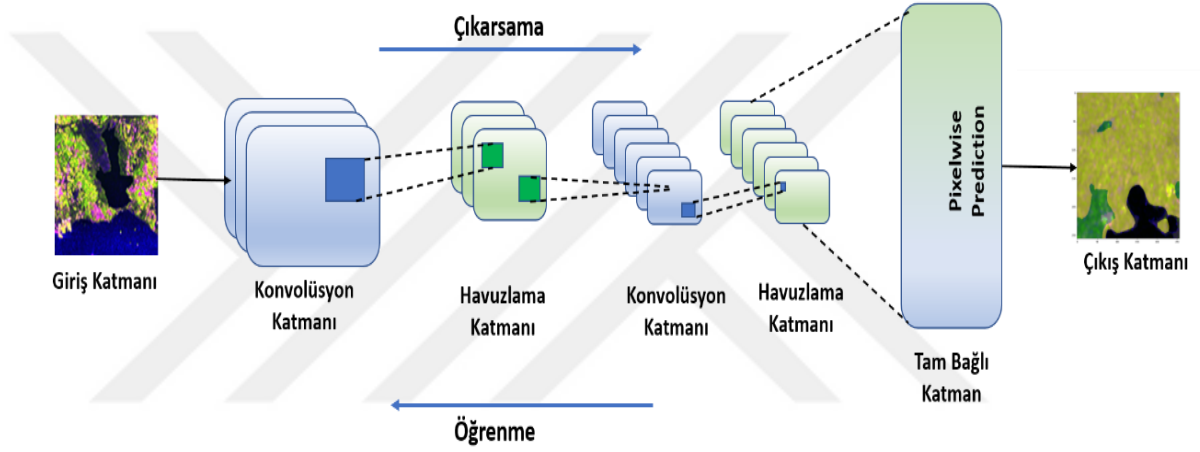
Bu nedenlerden dolayı alan çalışmasının çok büyük bir bölümü gözetimsiz öğrenme algoritmalarını kullanmış ve sonuçlar belli bir başarı düzeyinde kalmıştır. Yapılan bu çalışma ile etiketlenmiş veri setinin elde edilme aşamaları detaylı olarak açıklanacak, gözetimli öğrenme metotları ile daha yüksek başarılar elde edilmeye çalışılacaktır.

Görüntü bölütlemesinde temel olarak 4 teknik kullanılmaktadır. Bu teknikler; Bölge Temelli Görüntü Bölütlemesi (Region Based Image Segmentation), Ayrıntı Bazlı Görüntü Bölütlemesi (Edge Based Image Segmentation), Kümeleme Bazlı Görüntü Bölütlemesi (Clustering Based Image Segmentation) ve olan Konvolüsyonel Sinir Ağları (Convolutional Neural Network-CNN) Bazlı Görüntü Bölütlemesi (CNN Based Image Segmentation)dir (Kaushik ve Kumar 2019).

Bu çalışmada CNN bazlı görüntü bölütlemesi uygulanacağından öncelikle CNN hakkında daha sonra literatür incelemesi hakkında detaylı bilgi verilecektir.

3.1 Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağları, (Lecun vd. 1989) tarafından ortaya çıkarılan ve en fazla kullanılan derin öğrenme modelidir. Bu model yıllar içinde görüntü bölütlemesini de kapsayan değişik görüntü işleme görevleri için kullanılmıştır. CNN'nin ana amacı, görüntünün sahip oldukları özellikleri çıkarmak ve hangi amaç için kullanılıyorsa o amaç için bir sonuç elde etmektir. CNN mimarisi temel olarak üç katmandan oluşmaktadır: Giriş katmanı, saklı katmanlar ve çıkış katmanı. Saklı katmanlar, konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katmanı içermektedir. CNN mimarisi Şekil 3.2'de gösterilmiştir.



Şekil 3.2 CNN mimarisi

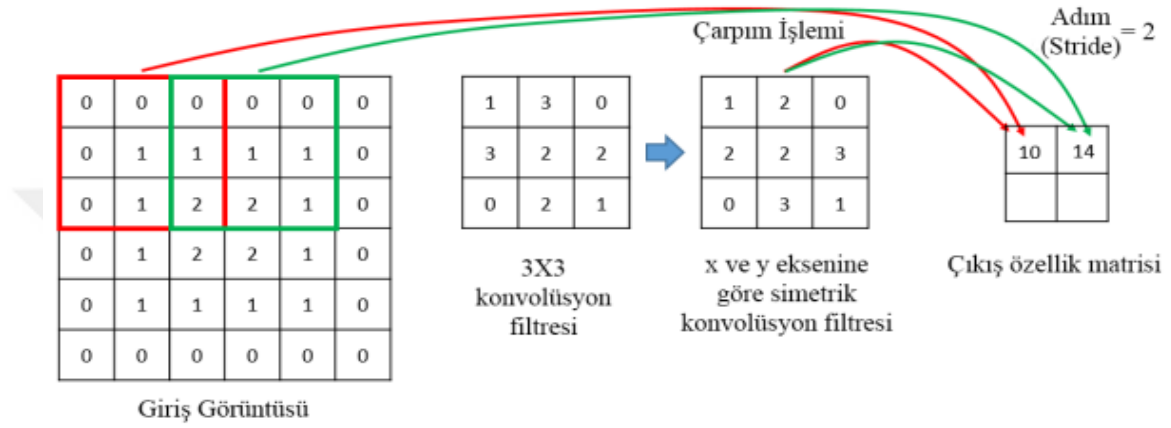
3.1.1 Konvolüsyon katmanı

Konvolüsyon katmanı CNN mimarisinde en çok kullanılan ve en önemli katmandır. Bu katman özellik çıkarımını yaptığı için en temel katmandır. Kenar ve köşelerin, renklerin tespit edildiği katmandır. Bu özellikler, iki matris arasında bir iç çarpım kullanılarak çıkarılır. Bunlardan ilki, ağız öğrenilebilir parametreleri olan çekirdekler veya filtreler olarak adlandırılır. Diğeri ise matris görüntünün bir parçasıdır.

Bu katmanda filtreler uygulanarak görüntünün özellikleri ortaya çıkarılır. Filtreler görüntünün üzerinde sabit adım kaydırma (stride) işlemi ile yapılır. İstenen sonuçları elde edebilmek için adım kaydırma için kullanılacak boyutların seçilmesi çok önemlidir. Görüntü üzerinde filtreleme yapılırken, filtrenin üzerinde bulunduğu görüntünün parçasıyla filtrenin iç çarpımı hesaplanır. RGB görüntüleri (genişlik * yükseklik * 3) için

çekirdekler, giriş görüntüsünden daha küçük genişlik ve yüksekliğe sahiptir, ancak derinlik parametresi veya kanal parametresi görüntünün üçüncü parametresine eşittir. Çıktı derinlik çekirdek sayısına eşittir.

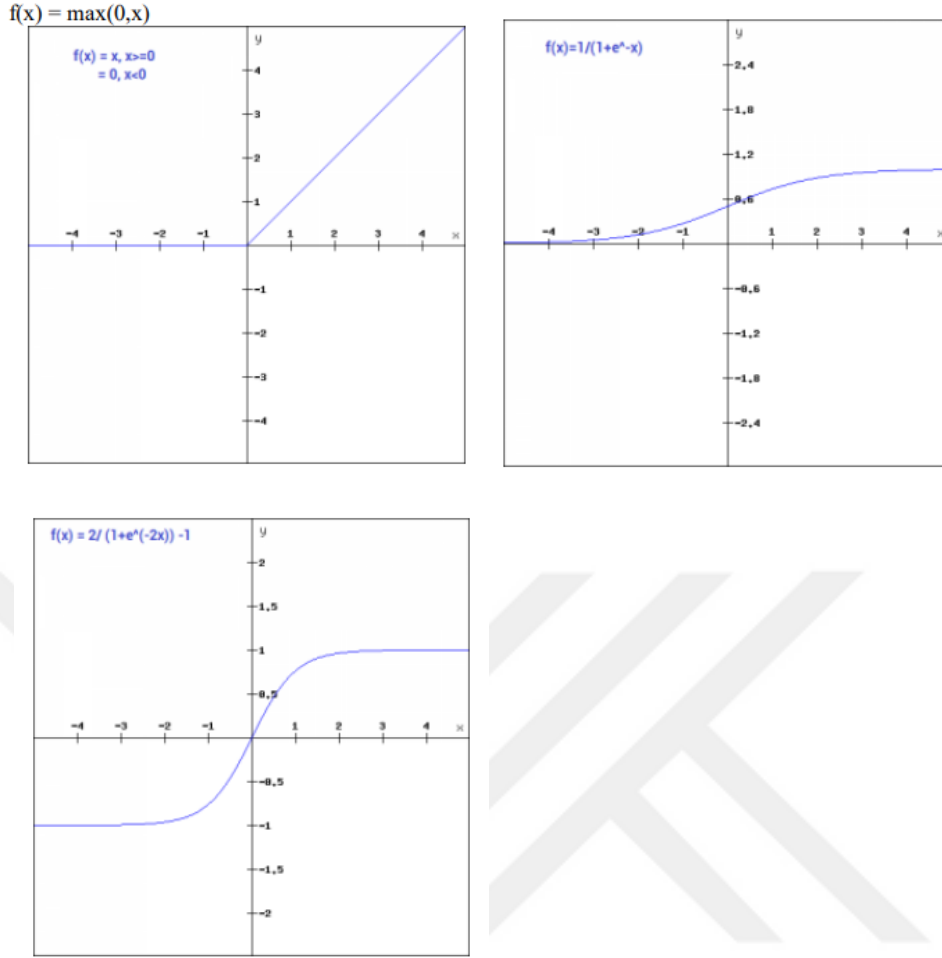
Çekirdekler aynı görüntü genişliğine ve yüksekliğine sahip olmasa da, tüm görüntü pikselleri için tüm çekirdeklere uygulamak için adım kaydırma işlemi gereklidir. Adım kaydırma, filtrelerin giriş verileri üzerinde kaç birim hareket ettiğini ifade eder.



Şekil 3.3 Konvolüsyon işlemi (Ünlü 2019)

Örnek konvolüsyon işlemi Şekil 3.3'de gösterilmiştir. 3x3 lük konvolüsyon filtresi uygulanmış ve adım kaydırma 2 olarak belirlenmiştir. Filtre, 2 kaydırarak tüm veri üzerinde çarpım ile uygulanır.

Her bir konvolüsyonel katmandan sonra, bir aktivasyon fonksiyonu bulunmaktadır. CNN'de kullanılan bir çok aktivasyon fonksiyonu bulunmaktadır (Sharma vd. 2020). Bunlardan bazıları: RELU, sigmoid, hyperbolic tangent, Softmax vb. dir. Şekil 3.4'de örnek olarak aktivasyon fonksiyonları gösterilmiştir. Aktivasyon fonksiyonları temel olarak kullanılan nöronların aktif edilip edilmeyeceğine karar veren fonksiyonlardır. Modelin çıktısını belirlemede yardımcı olan temel etmendir.



Şekil 3.4 Aktivasyon fonksiyonları (sırasıyla RELU, sigmoid ve hyperbolic tangent)
(Sharma vd. 2020)

3.1.2 Havuzlama katmanı


Havuzlama katmanı, girdinin boyutlarını (derinlik değerini değiştirmeden sadece genişlik ve yükseklik) azaltma kabiliyeti nedeniyle çok önemli bir katmandır. Bu azalma, hesaplamaları daha kolay ve daha az karmaşık hale getirir; ayrıca özellik çıkarma işlemini daha doğru hale getirir. Havuzlama katmanları ayrıca kayan pencereler içerir, ancak evrişimli katmandan farklı olarak öğrenmesi gereken ağırlıklara sahip değildir, hatta giriş değerleriyle çarpılabilir.

Havuzlama örnekleri Şekil 3.5’de gösterilmektedir. Max pooling için değerlerin maksimum değeri alınırken, average pooling için değerlerin ortalama değerleri alınmaktadır.

Havuzlama için en çok kullanılan 2 fonksiyon bulunmaktadır (Machine Learning Mastery 2019):

Max Pooling: Uygulanan alandaki maksimum değeri çıktı olarak alır. Bu işlem ile ağıın boyutu azalmakta fakat bazen veri kaybı oluşabilmektedir.

Average Pooling: Uygulanan alandaki ortalama değeri çıktı olarak alır.



Şekil 3.5 Havuzlama örnekleri

3.1.3 Tam bağlı katman

Yukarıdan aşağıya oluşan bu yapı genellikle bir piramit yapısı oluşturur, bu katmanlardaki parametrelerin sayısı nihayet istenen sınıf sayısına ulaşana kadar yakınlaşmaya devam etmektedir. Katmandaki gizli birimlerin sayısını artırmak, ağıın öğrenme yeteneğini artırmaktadır, ancak ağıın doğruluğunda bir genel sınır bulunmaktadır. Genellikle deneme ile seçilen bu sürecin formülasyonu yoktur (Kaushik ve Kumar 2019). Araştırmadaki ağların çoğu, genellikle 64'ün katındaki birim sayısı ile iyi performans göstermektedir. Evrişimli katmanların çıktılarını düzleştirdikten sonra ağıın yeterli desen geçirilirse iki veya üç katmanlı ağlar genel olarak tercih edilmektedir.

3.1.4 Kullanılan diğer önemli parametre ve fonksiyonlar

Konvolüsyonel sinir ağlarını etkileyen ve modelin başarısını etkileyen bir çok değişken ve etken bulunmaktadır. Bunlardan en temel olanları yukarıda anlatılmış olup bunun dışında başarıyı etkileyen bir çok katman bulunmaktadır. Bunlardan ilki öğrenme hızıdır.

Öğrenme hızı, kayıp fonksiyonunun değerini minimize etmek amacıyla, her yineleme adımında ne kadar değişkenlik göstereceğini optimize eden bir parametredir. Genel olarak başlangıçta 0,1 veya 0,01 değerleri kabul edilir. Öğrenme oranı büyük olduğunda eğitimin süresi kısa, öğrenme oranı büyük olduğunda ise eğitim süresi uzun olacaktır (Bengio 2012).

Diğer önemli bir katman seyreltme katmanıdır. Seyreltme katmanı eğitim esansında bazı nöronların artık kullanılmamasını ve eğitimin daha başarılı ilerlemesine yardımcı olmaktadır. Giriş katmanındaki nöronların %20, gizli katmanlardaki nöronların %50'sinin seyreltilmesinin en uygun olduğu görülmüştür (Srivastava vd. 2014).

Bunun dışında modelin başarısını etkileyen bir diğer parametre eğitim tur sayısıdır. Eğitim tur sayısı eğitimin başlangıcında tanımlanan bir değerdir. Eğitim tur sayısı genellikle büyük olarak tanımlanır ve eğitim sürecinde sürekli takip edilerek, modelin başarısına göre eğitim sonlandırılır.


3.2 Literatür İncelemesi

SAR görüntülerinin bölütlenmesi konusunda bir çok farklı algoritma ve veri seti kullanılmıştır. Tüm bu çalışmalarda ortak konular aşağıda belirtilen alt başlıklarda anlatılacak ve kullanılan metot ve materyallere göre oluşan sonuçlar karşılaştırılacaktır.

3.2.1 Kullanılan veri setleri

Hava ve uydu platformlarından elde edilen SAR görüntüleri veri seti olarak kullanılmıştır. Veri setlerindeki temel farklılık ise çok farklı kaynaklardan, ayrı bantlardan ve ayrı çözünürlüğe sahip olmalarıdır. Veri setlerinin çözünürlüğü ve gürültüsü başarıyı etkileyen en temel faktörlerden bir tanesidir. Bu çalışmada kullanılan veri setinin uydu platformu aracılığıyla elde edilecek olması sebebiyle veri seti olarak uydu görüntüleri kullanan makale ve tezler incelenmiştir.

Bu alanda en fazla kullanılan veri seti Amerika Hava Kuvvetleri tarafından üretilen, X-bant HH polarizasyonda elde edilmiş olan MSTAR veri setidir (Wang vd. 2020) . Örnek MSTAR görüntü örnekleri Şekil 3.6’da gösterilmektedir. Bunun dışında literatürde en çok kullanılan veri setleri 41 Sentinel-1 görüntüsü ve 11000 çeşit gemiden oluşan OpenSARShip 2.0 (Huang vd. 2018), ormanların kontrolü için oluşturulmuş olan ve orman/orman olmayan bölgeleri gösteren JAXA's ALOS PALSAR (Shimadaa vd. 2014) ve TerraSAR-X uydusundan elde edilen görüntülerden oluşan SARptical (Wang ve Zhu 2018) veri setleridir. Ayrıca, açık kaynak SAR veri setleri genel olarak (Zhu vd. 2021) çalışmasında tanıtılmıştır.



Şekil 3.6 MSTAR SAR görüntü örneği

3.2.2 Karşılaşılan ortak temel sorunlar

Literatür incelemesi sırasında tespit edilen ortak temel sorunlar aşağıda belirtilmiştir:

- 1) SAR görüntülerinin çözünürlüklerinin bölütlemeyi kolay yapabilecek kadar net olmaması
- 2) SAR görüntülerinde benek gürültüsünün olması
- 3) Etiketlenmiş veriye ulaşılamaması
- 4) Bazı SAR görüntülerinin ücretli olması

- 5) Veri setinin açık kaynak olmaması sebebiyle kullanılan veri setlerinde eğitim ve test görüntü sayılarının az olması.

3.2.3 Literatür özeti

SAR görüntülerinde yapılan çalışmalar, teknolojinin gelişmesiyle artmış ve çok çeşitli bir hal almıştır.

SAR teknolojisi uzun yıllardır kullanıldığı için, çok çeşitli çalışmalar yapılmış ve konvolüsyonel sinir ağlarının yaygın kullanılmasıyla çok başarılı sonuçlar elde edilmeye başlanmıştır. Konvolüsyonrl sinir ağları ile MSTAR veriseti kullanılarak yapılan çalışmada (Malmgren-Hansen ve Nobel-Jorgensen 2015), uzman kişilerce manuel bölütleme işleminin yerini alan SAR görüntülerine piksel bazında açıklama yapmanın yeni bir yolu önerilmiştir. Bu çalışma, nesnelerin ve sahnenin 3B CAD modellerine dayanır ve bunları bir SAR görüntüsündeki tüm pikseller için etiketlere dönüştürülmüştür.

SAR görüntülerinde yol bölütlemesi için yapılan çalışmada FCN-8s, Deep Residual U-Net, DeepLabV3+ modelleri karşılaştırılmış, TerraSAR-X görüntüleri (X bant) kullanılmış ve FCN-8s IoU değeri %45.46, precision %71.69 ve recall değeri 75.17 olarak tespit edilmiştir. Deep Residual U-Net IoU değeri %40.18 ve DeepLabV3+ IoU değeri de %45.64 olarak bulunmuştur (Henry vd. 2018).

Arazi örtüsü bölütlemesi ile ilgili bir çok çalışma yapılmıştır. Bu çalışmalardan birinde PolSAR görüntülerinde bölütleme için FCN ve U-Net kullanılmış olup, küçük veri setleriyle başarı oranı artırılmaya çalışılmıştır. FCN MIoU değeri 0.50 iken, U-Net MIoU değeri 0.44 olarak tespit edilmiştir (Wu vd. 2019). PolSAR görüntüleriyle yapılan bir başka çalışmada RF, FCN-32s, FCN-16s, FCN-8s, Segnet ve yeni önerilen FCN modelleri karşılaştırılmıştır. Encoder ve Decoderdan oluşan temel bir yapısı olan makale F1-score a göre değerlendirilmiştir. RF F1-score 0.74, FCN-32s F1-score 0.69, FCN-16s F1-score 0.75, FCN-8s F1-score 0.81, Segnet F1-score 0.76 ve yeni önerilen FCN F1-score 0.84 olarak bulunmuş ve yeni oluşturulan model başarıyı artırmıştır (Fariba vd. 2019). Diğer bir arazi örtüsü bölütlemesi çalışması da (Šćepanović vd. 2021), bu çalışmada olduğu gibi Sentinel-1 SAR görüntüleri ile yapılmıştır. Bölütlemede kullanılan

ve çok başarılı sonuçlar elde edilen derin öğrenme modellerinden 7 tane modeli kullanılmış olup, FC-DenseNet %90.7 ile en başarılı sonuç elde edilmiştir.

Etiketlenmiş veri setine ulaşamamasından dolayı gözetimsiz öğrenme metotları da çok tercih edilmiştir. Bunlardan ilkinde, alan düzleştirme ve etiket düzeltme (RSLC) (Shang vd. 2020) önerilmiştir. Görüntünün uzamsal bilgi polinomlarının etkilerini göstermek için düzleştirme kullanılmıştır. Bu çalışma, bölütleme sürecinin RSLC ile hızlı ve etkili bir şekilde gerçekleştirilebileceğini belirtir. Diğer bir çalışmada, Bir Convolutional Deep Neural Network (CDNN), kesilen alanları sınıflandırmak ve bu alanların SAR uydu görüntülerinde yetiştirme durumunu tespit etmek için kullanılır (Natteshan ve Kumar 2020). Bu amaçla, bölümlere ayrılmış veri kümesi, Yüksek Geçişli Uzamsal (HLS) Filtre ile eğitimde önceden işlenir. Daha sonra, test aşamasında sınıflandırma için Modifiye Bölge Yetiştirme (MRG) algoritması kullanılır ve sınıflandırılmış her bir mahsulün yetiştirme durumu Öklid Mesafesi (ED) ile tanımlanır.

Denizlerde yer alan buzulların bölütlemesi ile ilgili olarak yapılan çalışmada (Tan vd. 2018) Sentinel-1 SAR görüntüleri kullanımı ve yarı otomatik bölütleme hedeflenmiştir. Bu süreç iki aşamadan oluşmaktadır. Öncelikle deniz buzu yorumunda tercih edilen özellikler, random forest öznelik seçimi yöntemi ile belirlenmiştir. İkinci aşamada ise denetimsiz bir grafik kesim görüntü bölütlemesi uygulanmıştır. Sonuçlar, önerilen iş akışının Sentinel-1 görüntülerini uygun sayıda sınıfa bölebildiğini ve potansiyel su tanımlama oranının %95'e ulaştığını göstermiştir.

SAR görüntüleri denizlerde geni tespiti ve bölütlemesi alanında sıklıkla kullanılmış ve bir çok çalışma yapılmıştır. Yüksek çözünürlüklü SAR görüntüleri kullanılarak yapılan çalışmada (Wei vd. 2020), gemi tespiti ve instance bölütlemesi yapılmıştır. Konvolüsyonel sinir ağına dayalı nesne dedektörleri, kara-okyanus segmentasyonu olmadan bile SAR gemisi algılamada yüksek performans göstermekte, ancak gemi tespiti için SAR görüntülerinin nispeten küçük boyutu, sınırlı SAR eğitim örnekleri ve mevcut SAR gemisi veri kümelerindeki uygun olmayan açıklamalar gibi ilgili eksikliklerden dolayı mutlak başarı elde edilemediği için yeni Yüksek Çözünürlüklü SAR Veri Seti (HRSID) oluşturulmuştur. Toplamda 5604 SAR görüntüsü ve 16951 gemi içeren bu veri seti ile yüksek başarı elde edilmiştir.

SAR görüntüleri hava olaylarının tahmininde de etkili olarak kullanılmaktadır. Çığ bölütlemesi ile ilgili yapılan bir çalışmada (Bianchi vd. 2021) , derin öğrenme modelleri kullanılarak SAR görüntüleri ile denenmiştir. 118 adet Sentinel-1 SAR görüntüsü ile yapılan çalışmada, U-Net modeli kullanılmış olup, %54.3'lük bir IoU değeri elde edilmiştir.

Tarım ürünlerinin değişimi ve izlenmesi için SAR görüntüleri sıklıkla kullanılmaktadır. Bu kapsamda yapılan çalışmalardan birinde (Clauss vd. 2018) pirinç alanları SAR görüntüleri ile takip edilmiştir. Pirinç tarlalarının dağılımı hakkında bilgi, serayla ilgili metan emisyonları, hastalık bulaşması ve su kaynakları yönetimi bağlamında da önemlidir. Bu çalışmada pirinç yetiştirilen alanların doğru ve zamanında haritalanması için bu verilerin potansiyelini gösteren yeni bir yöntem geliştirilmiştir. Benek gürültüsüne karşı dayanıklı ve işlenecek veri miktarını azaltan, uzaysal olarak ortalamalı geri saçılım zaman serileri oluşturmak için süper piksel bölütlemesi kullanılmış ve %83'lük PA elde edilmiştir.

SAR görüntülerinin bölütlemesinde kullanılan bir diğer alan petrol sızıntılarının tespittir. SAR görüntüleri, denizdeki petrol sızıntılarının tespiti için değerli bir bilgi kaynağıdır. Petrol sızıntısı analizi için yapılan çalışmada (Cantorna vd. 2019), Envisat ve Sentinel-1 uydu görüntülerinde petrol sızıntılarının tespiti için kümeleme, lojistik regresyon ve konvolüsyonel sinir ağı algoritmalarının uygulanmasını ele almaktadır. Her ne kadar lojistik regresyon ve kümeleme algoritmaları petrol sızıntısı segmentasyonu için faydalı olarak kabul edilebilse de, konvolüsyonel teknikler ve sinir ağlarının kombinasyonu, düşük hesaplama süresi ile en iyi sonuçları elde ettiğini bu çalışma göstermiştir.

Ayrıca, kısa gösterimlere dayalı yeni bir yöntem ve hiyerarşik bulanık C-ortalama (FCM) yaklaşımı önerilmiştir (Shang vd. 2020). İlk olarak, görüntü özelliklerine göre piksel gruplarına ayrılır ve küçük pikselin oluşturulması için ana piksel grupları kullanılır. Daha sonra, bölütleme görevi için FCM kullanılır.

Diğer etkili SAR görüntü bölütleme çalışmaları da threshold-based (Zeng vd. 2014), clustering-based (Fen vd. 2013) , wavelet-based (Zhang vd. 2013) , and level set-based (Ebrahimia vd. 2014) metotları ile yapılmıştır. Son zamanlarda, bazı çalışmalar, speckle istatistiği gibi yayılma fonksiyonlarının yardımıyla verimli bölütleme kriterleri

sağladıkları için, bir SAR görüntü bölümlenmesini formüle etmek için seviye belirleme yöntemlerini kullanmıştır (Feng vd. 2012).

Derin öğrenme yöntemlerinin niteliklerini ve eksikliklerini belirlemek önemli bir görevdir. Çeşitli araştırmalarda bu amaçla Mc Nemar'ın testini kullanılmıştır. Mc nemar's testi ile 5 farklı makine öğrenmesi modeli sınıflandırma sonuçları için karşılaştırılmış ve bu testin başarısı gösterilmiştir (Bostanci ve Bostanci 2013).

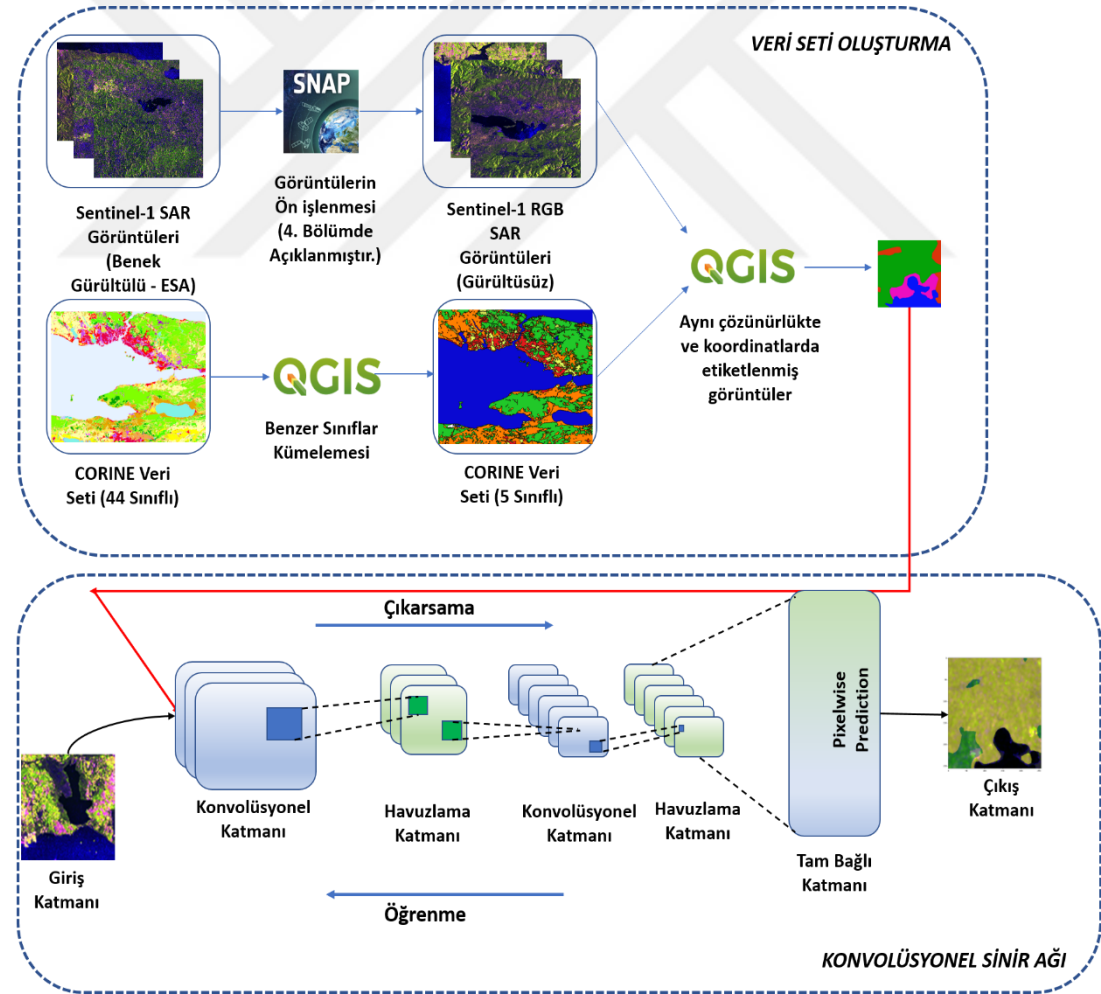
Bu çalışma en iyi derin öğrenme modellerini kullanmak üzere, yeni bir veri seti oluşturma sürecini önerdiği ve mIoU, MA ve PA değerleri ile değerlendirdiği için daha önceki çalışmalardan farklıdır. Bununla, SAR veri seti oluşturma ile başlayan ve derin öğrenme modeli değerlendirmesi ile biten süreç detaylı olarak diğer bölümlerde anlatılacaktır.

4. UYGULAMA

4.1 Genel Bakış

Yukarıda değinildiği gibi, SAR görüntülerinde bölütleme için kullanılan bir çok metot ve veri seti bulunmaktadır. Bu çalışmada öncelikle veri seti yaratılacak, daha sonra uygun modeller kullanılarak eğitim ve test yapılacak ve sonuçlar birbirleriyle karşılaştırılacaktır. Ayrıca kullanılan modeller birbirleriyle kıyaslanarak, en doğru model tespit edilmeye çalışılacaktır.

Veri setinin oluşturulma adımları aşağıda adım adım açıklanmıştır. Veri setinin oluşturulmasına müteakip kullanılan model ve materyaller anlatılmıştır. Görüntülerin elde edilmesi, ön işleme tabi tutulması ve görüntülerin etiketlenmesine müteakip, derin öğrenme modelleri kullanılmış olup, bu süreç şekil 4.1’de gösterilmiştir.



Şekil 4.1 Önerilen model

4.2 Veri Seti Oluřturma

Yukarıda anlatıldıđı gibi çeřitli bir çok veri seti olsa da, bu alıřmada ücretsiz bir setinin nasıl oluřturulduđu anlatılmıř ve bu veri setini derin renme modelleriyle kullanılarak sonular kıyaslanmıřtır.

Veri seti iin ncelikle, SAR grntleri Avrupa Uzay Ađansının (ESA) Copernicus (<https://scihub.copernicus.eu/dhus/#/home>) internet sitesinden ücretsiz olarak indirilmiřtir (Copernicus 2020). Sentinel-1 zellikleri yukarıda anlatılmıř olup, bu alıřma iin en uygun grntlerin Sentinel-1'den elde edilen IW modunda GRD'ye ait grntler olduđu anlařılmıřtır. Grntler Trkiye'nin belirli blmlerinden alınmıř olup izelge 4.1'de detaylı bilgiler sunulmuřtur.

izelge 4.1 Veri seti genel bilgileri

İstanbul, Trkiye	
Boyut,	12288x12288 piksel
Cođrafi Koordinat Batı ve Dođu,	28.443 , 29.546
Cođrafi Koordinat Gney ve Kuzey,	39.93 , 41.063
Referans Bilgiler	20210123-036260-0440DA-330D
İzmir, Trkiye	
Boyut,	12228x12228 piksel
Cođrafi Koordinat Batı ve Dođu,	26.604 , 27.703
Cođrafi Koordinat Gney ve Kuzey,	38.654 , 39.752
Referans Bilgiler	20210128-025357-03051D-2D81
Adana, Trkiye	
Boyut,	12228x12228 piksel
Cođrafi Koordinat Batı ve Dođu,	34.906 , 36.004
Cođrafi Koordinat Gney ve Kuzey,	36.643 , 37.742
Referans Bilgiler	20210120-025240-03015D-DC9A

Daha sonra elde edilen görüntüler Sentinel-1'in ücretsiz sağladığı SNAP (The Sentinel Applicaiton Platform) uygulamasında ön işleme işlemi yapılmıştır. Ön işleme için önerilen işlem adımları (Federico 2019) aşağıda olup, bu çalışmada da uygulanmıştır.

1) Thermal Noise Removal: Sentinel-1 SAR görüntülerin yoğunluğu, ek termal gürültüden dolayı özellikle çapraz polarizasyon kanalında bozulma yapmaktadır. Termal gürültü ortadan kaldırılması, özellikle tüm Sentinel-1 sahnesi içindeki geri saçılım sinyalinin normalleştirilerek ve çoklu alan edinme modlarında sahneler için alt alanlar arasındaki süreksizliklerin düşmesine neden olarak, alt alanlar arası dokudaki gürültü etkilerini minimum seviye indirir. Sentinel-1 seviye-1 ürünleri, her ölçüm veri seti için kalibre edilmiş ve doğrusal güçte sağlanan GRD verileriyle eşleşen gürültü profillerini ortaya çıkarmak için kullanılan bir gürültü arama tablosu (LUT) imkanı verir.

2) Apply Orbit File: SAR ürünlerinin meta veri bilgilerinde bulunan yörünge durum vektörleri sıklıkla yanlıştır. Uyduların kesin yörüngeleri iki üç gün sonra belirlenir ve ürünün ortaya çıkmasından uzun bir süre sonra kullanılabilir. SNAP'de mevcut olan kesin bir yörünge uygulama işlemi, ürün meta verilerindeki her SAR sahnesi için yörünge durum vektörlerinin otomatik olarak indirilmesine ve güncellenmesine izin vererek, doğru bir uydu konumu ve hız bilgisi sağlar.

3) Border Noise Romoval: Seviye-1 ürünler üretirken, Dünya'nın eğrilik farklılığını düzenlemek amacıyla örnekleme başlangıç zamanı değiştirilmelidir. Bu sırada, azimut ve menzil sıkıştırma, görüntü kenarlarında radyometrik artefaktlara yol açar. SNAP'de operatör olarak bulunan sınır gürültü giderme algoritması, sahne kenarlarındaki düşük yoğunluklu gürültüyü ve geçerli olmayan verileri yok etmek için tasarlanmıştır.


4) Calibration: Kalibrasyon, dijital piksel değerlerini radyometrik olarak kalibre edilmiş SAR geri saçılımına dönüştüren süreçtir. Kalibrasyon denklemini uygulamak için ihtiyaç duyulan bilgiler Sentinel-1 GRD içinde bulunmaktadır; özellikle, ürüne açıklama olarak eklenen bir kalibrasyon vektörü, görüntü yoğunluğu bilgilerinin sigma sıfır değerlerine basit bir şekilde dönüşümünü sağlar. Kalibrasyon, seviye-1'de ürün oluşumu esnasında uygulanan ölçeklendirme faktörünü ters çevirir ve mutlak kalibrasyon sabiti dahil olmak üzere sabit bir sapma ve aralığa bağlı bir kazanç uygular.

5) Speckle Filter: SAR görüntülerinde gürültü olarak görünen benek, birçok temel saçıcıdan yansıyan dalgaların girişiminden dolayı ortaya çıkmaktadır. Benek gürültüsünü yok edilerek görüntü kalitesini yükseltmek temel hedeflerdendir. SAR'ın erken bir işleme aşamasında böyle bir işlem uygulandığında veri, benek müteakip dönemde yayılmaz.

6) Terrain correction: Her bir pikselin yerini düzenlemek için bir dijital yükseklik modeli ile, topografyanın sebep olduğu kısalma ve gölgeler gibi geometrik düzensizliklerin düzeltilmesidir. Tam konum belirleme için meta verilerde, radar zamanlama açıklamalarında ve eğimden yer aralığına dönüştürme parametrelerinde mevcut yörünge durumu vektör bilgisini referans dijital yükseklik modeli verileriyle birlikte kullanır.

Ön işleme adımlarında sonra yüksek çözünürlüklü görüntüler RGB olarak kaydedilmiştir. Sentinel-1 görüntülerinde RGB görüntüleri elde etmek için dual pol ratio, dual pol multiple ve dual pol difference seçenekleri bulunmaktadır. Dual pol ratio kullanıldığında kırmızı VV kanalını, yeşil VH kanalını ve mavi VV/VH kanalını kullanmaktadır. Dual pol multiple ise kırmızı VV kanalını, yeşil VH kanalını ve mavi VV*VH kanalını, dual pol difference ise kırmızı VH kanalını, yeşil VV kanalını ve mavi VV-VH kanalını kullanmaktadır. Bu çalışma için RGB görüntüleri dual pol ratio ile çıkartılmıştır. Bu çalışmada özellikleri Çizelge 4.1'de sunulan 3 adet yüksek çözünürlüklü görüntü kullanılmış olup, bu üç görüntü 256x256 piksellik görüntülere bölünmüş ve toplamda 6722 görüntü elde edilmiştir. Elde edilen görüntülerden örneklem olarak bazıları Şekil 4.2'de sunulmuştur. Ayrıca Copernicus'un açık kaynak olarak sunduğu CORINE Land Cover veri seti ücretsiz olarak indirilmiştir (Corine Land Cover 2020). Bu veri setinde toplamda 44 sınıf bulunmaktadır. SAR görüntüsünün çözünürlüğünden dolayı, bu veri seti QGIS programı vasıtasıyla 44 sınıftan 5 sınıfa düşürülmüştür. Bu sınıflar;

- 1) Şehir Alanlar
- 2) Ekilebilir Arazi
- 3) Ormanlık Alan
- 4) Su (Deniz,göl,nehir vb.)
- 5) Diğer Alanlar.



Şekil 4.2 Örnek RGB SAR görüntüleri

CORINE Land Cover veri seti 5 sınıfa düşürüldükten sonra, QGIS programı vasıtasıyla SNAP programından elde edilen görüntüler ile aynı koordinatlardan ve aynı çözünürlükte olacak şekilde kesilmiştir. Sonuç olarak, QGIS programı ile 5 sınıflı 6722 RGB etiketlenmiş görüntü, SNAP programı vasıtasıyla da 6722 RGB SAR görüntüsü elde edilmiştir.

4.3 Eğitim ve Materyaller

Bu çalışmada MMSegmentation (Anonymous 2020) toolu, tek bir 11 GB ekran kartlı GTX 1080TI üzerinde çalıştırılmıştır. MMSegmentation Pytorch altyapısını kullanan açık kaynak bir semantik bölütleme aracıdır. Bu toolu kullanmak için öncelikle veri seti custom hale getirilmiş olup, müteakiben tolda bulunan config ayarları modifikasyon ile uyumlu hale getirilmiş ve eğitime başlanmıştır. Yeni oluşturulan 256x256 piksellik veri setinde %80'i eğitim için, kalanı da test işlemi için ayrılmıştır.

Data augmentation (veri artırma) ve normalization (normalleştirme) eğitim veri verisinde kullanılmıştır. Data augmentation (veri artırma) için görüntüler yatay ve dikey olarak çevirilmektedir. ADAM iyileştiricisi kullanılmış olup başlangıçta öğrenme katsayısı 0.003 olarak belirlenmiş ve her iterasyondan sonra öğrenme katsayısı üstel 0.9 oranında düşürülmüştür. Her bir modelde 80.000 iterasyon uygulanmış olup eğitimde en başarılı modeller kaydedilerek test esnasında kullanılmıştır.

IoU (Intersection over Union), toplam yüzeyleri (birleşim) üzerinden tahminler ve etiketler (kesişim) arasındaki örtüşme oranını verdiği için segmentasyon kalite değerlendirmesi için kullanılan en önemli metriklerden bir tanesidir. Bu çalışmada modeller mIoU (mean Intersection over Union), MA (Mean Accuracy) ve PA (Pixel Accuracy) metrikleri kullanılarak değerlendirilecektir. IoU, mIoU, MA ve PA değerlerinin matematiksel karşılıkları aşağıda belirtilmiştir (Wang vd. 2020).

$$IoU = \frac{TP}{TP + FP + FN}$$

$$PA = \frac{\sum_i n(i, i)}{\sum_i \sum_j n(i, j)}, MA = \frac{1}{C} \sum_i \frac{n(i, i)}{\sum_j n(i, j)}$$

$$mIoU = \frac{1}{C} \sum_i \frac{n(i, i)}{\sum_j n(i, j) + \sum_j n(j, i) + n(i, i)}$$

n: piksel sayısı, i: hedeflenen sınıf, j: tahmin edilen sınıf, C: toplam sınıf sayısı

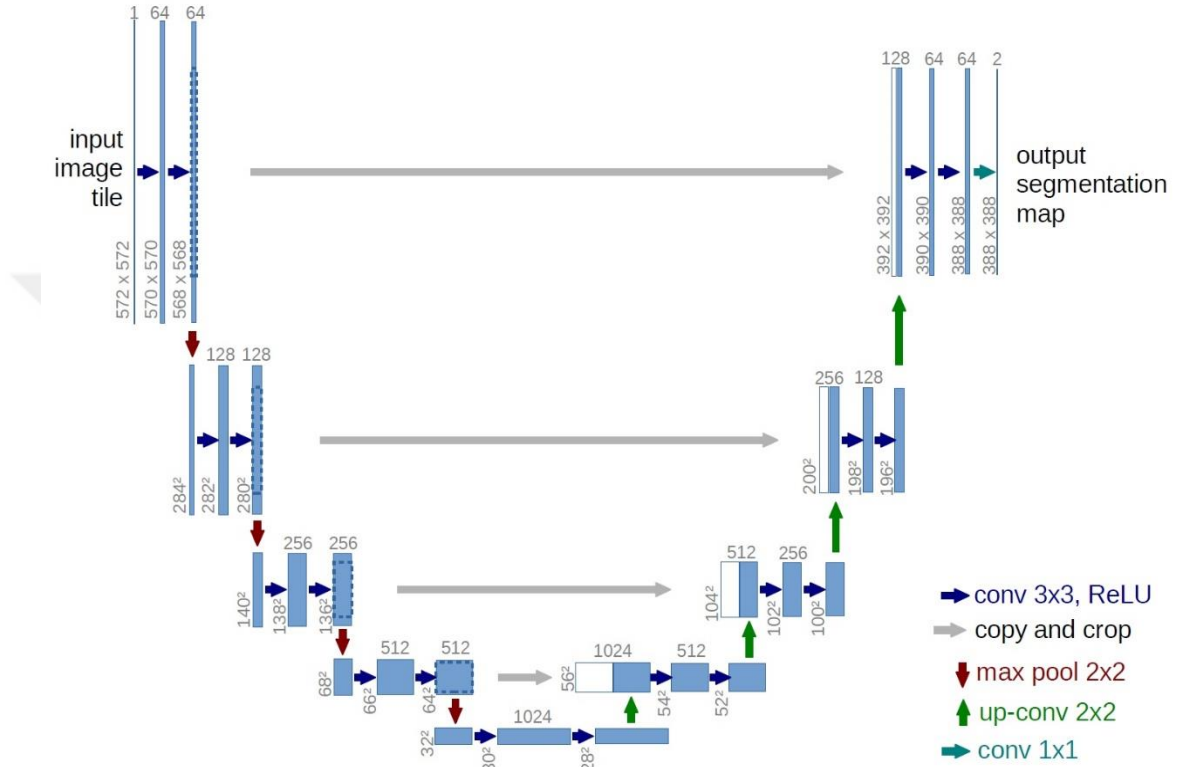
4.4 Modeller

Literatürde SAR görüntülerinin bölütlenmesi için yapılan araştırmalar incelendiğinde kullanılan mimariler arasında en başarılı olanlar arasından U-Net, PSPNet ve HRNet kullanılacak ve sonuçlar birbirleriyle karşılaştırılacaktır.

4.4.1 U-Net

U-Net, veri setinin küçük olması durumunda olsa dahi, piksel seviyesinde bölütleme yapan bir çok mimariye göre yüksek başarı imkanı sağlamaktadır (Anonim 2020). U-Net biomedikal alanında başarılı bir şekilde kullanıldıktan sonra (Ronneberger vd. 2015), görüntü bölütlemesi alanında yaygın bir şekilde kullanılmaya başlandı. SAR görüntülerinde tercih edilmesinin sebebi ise az sayıda eğitim verisi ile daha başarılı

sonular elde edebilmesidir. U-Net ana mimarisi isminden de anlařılacađı üzere U harfi gibi olup genel mimarisi Őekil 4.3’de gsterilmiřtir. Temel olarak iki blmden oluřmaktadır. İlk blmde ykseklik ve geniřlikte boyut azaltma iřlemi yapılırken, grntdeki ieriđi ortaya ıkarmak temel hedefdir. İkinci blmde ise boyut artırma iřlemi yapılırken bltmeye alıřılan blgeyi dođru bir Őekilde blmeye alıřır.

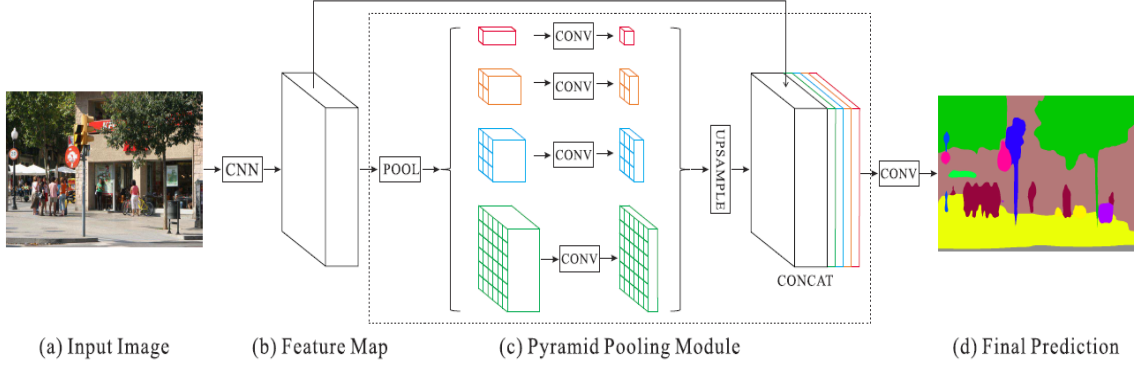


Őekil 4.3 U-Net mimarisi (Ronneberger vd. 2015)

4.4.2 Pyramid Scene Separation Network (PSPNet)

PSPNet, farklı blge tabanlı bađlam birleřtirme yoluyla kresel bađlam bilgisinden yararlanan bir piramit ayrıřtırma modln kullanan bir anlamsal bltleme modelidir. (Zhao vd. 2018). Kullanılan lokal ve global anlamsal bilgiler bltlemedeki tahmini daha gvenilir hale getirmektedir. Őekil 4.4’de PSPNet genel mimarisi gsterilmiřtir. Pyramid Pooling Module, modelin grntdeki kresel bađlamı yakalamasına yardımcı olduđu iin bu modelin ana parasıdır ve bu da pikselleri grntde mevcut olan kresel bilgilere gre sınıflandırmasına yardımcı olur. Feature map adımından sonra, farklı boyutlarda pooling iřlemi uygulanır ve daha sonra bir evriřim katmanından geirilir. Daha sonra,


pooling işlemi yapılmış özellikler üzerinde orijinal özellik haritası ile aynı boyutta olmaları için Upsample işlemi gerçekleştirilir.



Şekil 4.4 PSPNet mimarisi (Zhao vd. 2017)

4.4.3 High-Resolution Network (HRNet)

HRNet öncelikle insanların hareketlerindeki duruşlarını tahmin etmek için ortaya çıkmıştır (Sun 2019). Daha sonra üzerindeki modifikasyonlarla semantik bölütleme, nesne tespiti ve görüntü sınıflandırması gibi genel görüntü işleme alanlarında başarılı bir şekilde kullanılmıştır. HRNet tüm süreç boyunca yüksek çözünürlük sunmaktadır. Yüksek çözünürlüklü bir evrişim akışından başlanıp, kademeli olarak yüksek-düşük çözünürlüklü evrişim akışlarını birer birer ekleyerek, çok çözünürlüklü akışlar paralel olarak birbirine bağlanmaktadır. HRNet aslında, giriş verilerinin yüksek çözünürlüklü temsilini koruyarak bunları yüksek ile düşük çözünürlüklü alt ağlarla paralel olarak birleştirirken, verimli hesaplama karmaşıklığını ve parametrelerin sayısını koruyarak yenilik ortaya koymuştur. 4 evreden oluşan HRNet mimarisi Şekil 4.5’de sunulmuştur.



Şekil 4.5 HRNet mimarisi (Sun vd. 2019)

4.5 Mc Nemar's Testi

Mc Nemar's testi, ölçümle bulunan sürekli bir değişken için değişik iki zaman ya da durumdaki değerleri arasında fark olup olmadığının anlaşılması için yapılan testtir. Bu çalışmada kullanılan modeller birbirleriyle karşılaştırılacak ve hangi modelin daha başarılı olduğu ortaya koyulmaya çalışılacaktır. Mc Nemar's testi için z değeri hesaplanmakta ve modeller karşılaştırılmaktadır. Z değeri ortalama ile veri arasındaki uzaklığı belirtir ve aşağıdaki gösterildiği gibi hesaplanmaktadır:

$$z = \frac{(|A_{1,0} - A_{0,1}| - 1)}{\sqrt{A_{1,0} + A_{0,1}}}$$

X ve Y adında iki algoritma olduğunu düşünürsek; $A_{1,0}$, X algoritmasının başarılı, Y algoritmasının başarısız olduğu durumları vermektedir. $A_{0,1}$, X algoritmasının başarısız, Y algoritmasının başarılı olduğu durumları vermektedir. Yukarıda belirtilen formüle göre sonuç hesaplandığında, eğer z değeri 0 çıkarsa, iki algoritma benzer seviyede başarılıdır denmektedir. z değeri pozitif yönde ne kadar artarsa, başarı seviyelerinin farklılaştığı söylenmektedir. Z değerine bağlı güven parametresi (confidence level) ile tahmini başarı durumları Çizelge 4.2'de sunulmuştur:

Çizelge 4.2 z değerine bağlı güven parametreleri (McNemar 1947)

z değeri	Tek Taraflı Tahmin	İki Taraflı Tahmin
1.645	%95	%90
1.960	%97.5	%95
2.326	%99	%98
2.576	%99.5	%99

Tek taraflı tahmin, tek yönlü tahminler için kullanılmaktadır. Yalnızca negatif ya da pozitif bölgedeki hesaplamalarda kullanılır. İki taraflı tahmin de ise çift yönlü tahminleme bulunmaktadır. Pozitif ve negatif olmak üzere tüm olasılık değerleri birlikte hesaplanmaktadır.

Bu çalışmada, öncelikle test amacıyla kullanılan 1345 görüntünün her bir tanesinin PA değeri hesaplanmakta, daha sonra her bir görüntü için modellerin PA değerleri

birbirleriyle karşılaştırılmaktadır (HRNet-PSPNet, HRNet-UNet, PSPNet-UNet). Bu karşılaştırma esnasında PA değerlerine göre yüksek modele 1, küçük modele 0 değeri verilmektedir. Eşit PA değerleri hesaplamaaya dahil edilmemiştir. Daha sonra z değeri, hesaplama formülüne göre hesaplanmıştır.



5. DEĞERLENDİRME

Bu bölümde, modellerin semantik bölütleme sonuçları gösterilmiş ve bölütleme performansları kıyaslanmıştır. Modellerin performans değerlendirmesi için ayrıca Mc Nemar's testi uygulanmıştır. Müteakiben genel bir değerlendirme yapılmıştır.

5.1 Bölütleme Performansları

Benek gürültülü görüntüler ile gürültüsüz görüntülerin tüm sınıflar için tüm modeller ile kullanılarak ayrı ayrı mIoU ve MA değerleri hesaplanmış olup Çizelge 5.1'de U-Net'e, Çizelge 5.2'de PSPNet'e ve Çizelge 5.3'de HRNet'e ait sonuçlar sunulmuştur.

Çizelge 5.1 U-Net modeli bölütleme sonuçları

Sınıflar	Benek Gürültülü Görüntüler		Gürültüsüz Görüntüler	
	IoU %	Acc %	IoU %	Acc %
<i>Şehir Alanlar</i>	12.29	25.21	18.06	34.84
<i>Ekilebilir Arazi</i>	57.57	65.12	58.64	67.74
<i>Ormanlık Alan</i>	69.09	80.34	71.35	83.46
<i>Diğer Alanlar</i>	70.67	83.78	72.17	85.42
<i>Su (Deniz, göl, nehir vb.)</i>	92.67	94.15	94.15	95.58
Ortalama	60.46	69.72	62.87	73.41

Çizelge 5.2 PSPNet modeli bölütleme sonuçları

Sınıflar	Benek Gürültülü Görüntüler		Gürültüsüz Görüntüler	
	IoU %	Acc %	IoU %	Acc %
<i>Şehir Alanlar</i>	14.86	27.91	15.20	32.06
<i>Ekilebilir Arazi</i>	62.41	68.94	64.32	71.23
<i>Ormanlık Alan</i>	73.87	84.04	77.43	87.92
<i>Diğer Alanlar</i>	74.45	86.63	78.36	89.53
<i>Su (Deniz, göl, nehir vb.)</i>	92.11	94.21	94.66	96.90
Ortalama	63.54	72.34	65.99	75.53

Çizelge 5.3 HRNet modeli bölütleme sonuçları

Sınıflar	Benek Gürültülü Görüntüler		Gürültüsüz Görüntüler	
	IoU %	Acc %	IoU %	Acc %
<i>Şehir Alanlar</i>	21.13	39.77	27.13	44.27
<i>Ekilebilir Arazi</i>	71.54	83.24	74.47	85.20
<i>Ormanlık Alan</i>	72.33	82.74	74.06	84.71
<i>Diğer Alanlar</i>	74.49	86.21	79.59	89.67
<i>Su (Deniz, göl, nehir vb.)</i>	93.51	95.56	97.56	98.49
<i>Ortalama</i>	66.6	77.50	70.60	80.47

Elde edilen sonuçlar incelendiğinde, tüm modellerin şehir alanları bölütlemesi konusunda başarısız olduğunu, Su (Deniz, göl, nehir vb.) alanları için bölütlemeye ise son derece başarılı olduğu göstermektedir. Diğer alanların bölütlemesinde ise kısmen başarılı olduğu ortaya çıkmaktadır. Benek gürültülerinin kaldırılması ile tüm sınıflarda başarı oranını yaklaşık %3 artırmıştır.

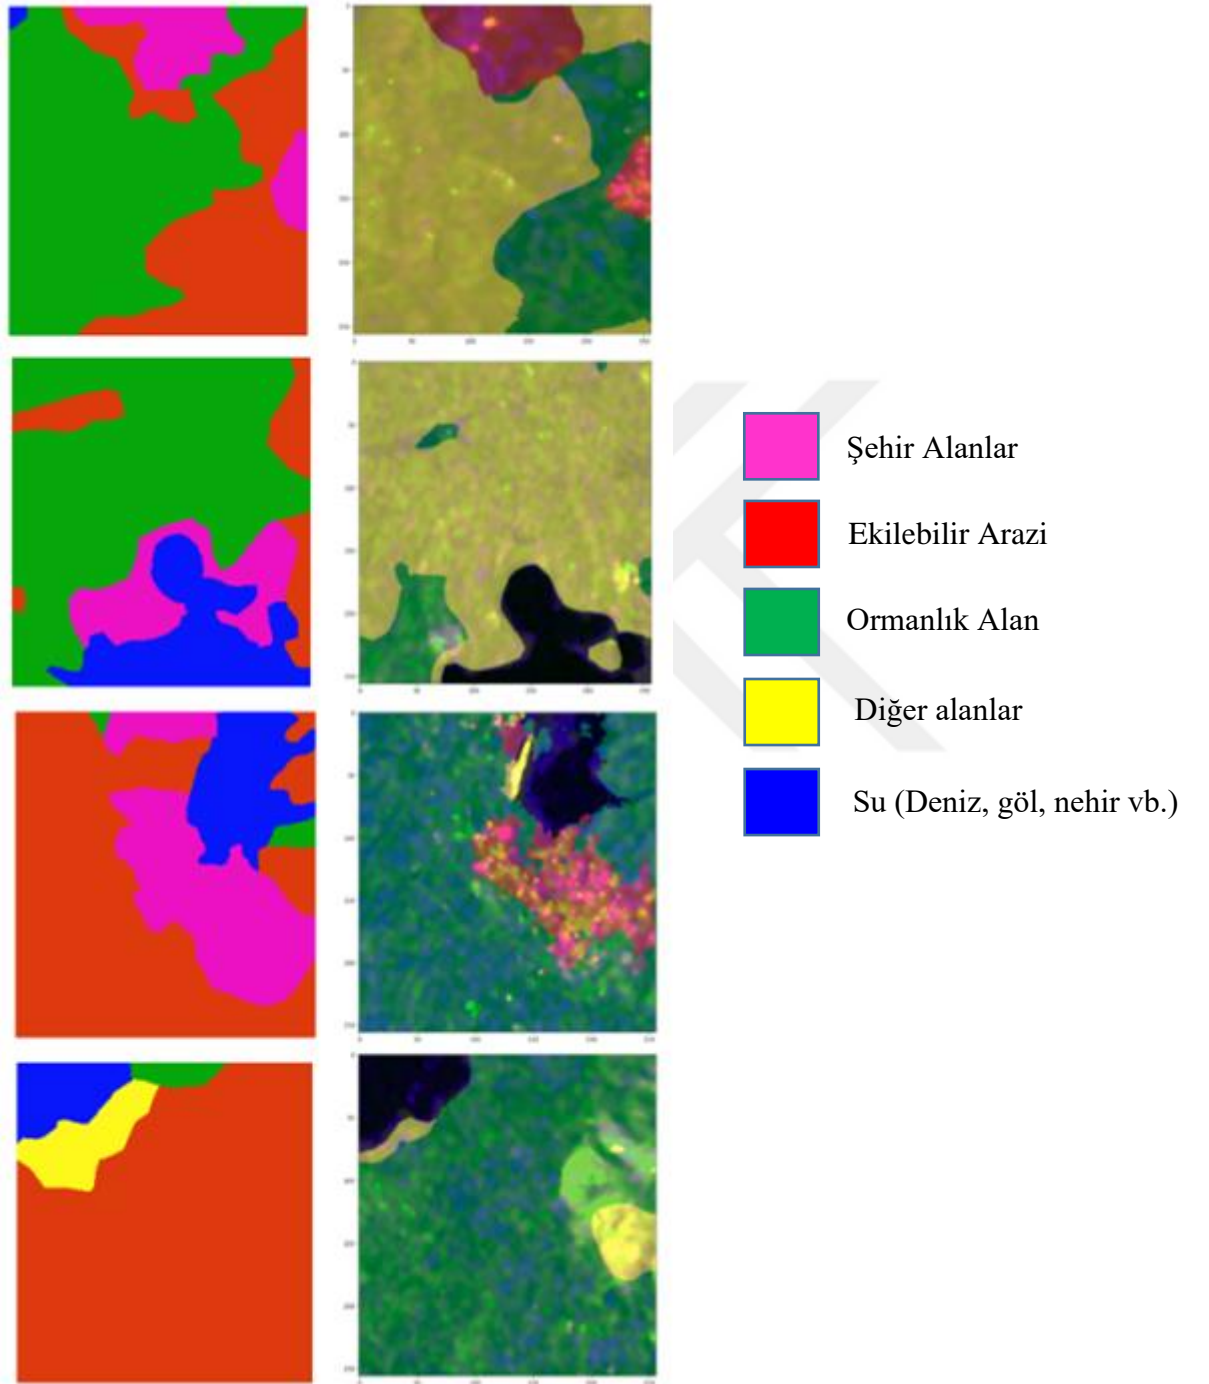
Yukarıdaki çizelgelerde gösterildiği gibi HRNet modeli ile mIoU değeri %70.60 olarak, MA değeri ise %80.47 olarak hesaplanmış ve en büyük başarı bu model ile elde edilmiştir. Sonuçlara göre en başarılı model olarak HRNet, daha sonra PSPNet ve en son olarak U-Net ortaya çıkmıştır. Modeller ayrıca Mc Nemar's testi ile kıyaslanacak ve başarı durumları tekrar gözden geçirilecektir.

Kullanılan modeller ayrıca PA değerlerine göre birbirleri ile karşılaştırılmışlardır. Çizelge 5.4'de mIoU, MA ve PA değerleri birlikte sunulmuştur. Sonuçlar bu konuda başarılı bir çalışma olan (Šćepanović vd. 2021) ile kıyaslanmıştır.

Çizelge 5.4 mIoU, MA ve PA değerleri karşılaştırma çizelgesi

	U-Net	PSPNet	HRNet	FC-DenseNet (Šćepanović 2021)
<i>mIoU %</i>	62.87	65.99	70.60	-
<i>MA Değeri %</i>	73.41	75.33	80.47	-
<i>PA Değeri %</i>	88.59	90.74	92.23	90.7

HRNet modelinin kullanılması sonucunda ortaya çıkan bölütlenmiş görüntülerden örnekler Şekil 5.1’ sunulmuştur. Soldaki sütunda görüntülerin etiketlenmiş hali yer alırken sağda bölütleme sonucunda ortaya çıkan görüntüler yer almaktadır.



Şekil 5.1 HRNet modelinin uygulanması sonucu bazı örnekler

5.2 Mc Nemar's Test Sonuları

Uygulanan modeller sonucunda en başarılı modelin HRNet modeli olduėu üst kısımda anlatılmıştır. Bu bölümde ise Mc Nemar's testi ile hangi modelin daha başarılı olduėunu tekrar değerlendirilmiştir. Mc Nemar's testinin nasıl uygulandıėı 4'üncü bölümde açıklanmıştır. 1345 test görüntüsünün PA değeri bulunmuş olup birbiriyle kıyaslanmıştır. Karşılaştırma için yapılan örnek değerler Çizelge 5.5'de gösterilmiştir.

Çizelge 5.5 Her bir test görüntüsü için modellerin PA değeri ve kıyas örnekleri

Görüntü Nu.	HRNet PA Deėeri	PSPNet PA Deėeri	U-Net PA Deėeri	HRNet-PSPNet		HRNet-UNet		PSPNet-UNet	
				$A_{(1,0)}$	$A_{(0,1)}$	$A_{(1,0)}$	$A_{(0,1)}$	$A_{(1,0)}$	$A_{(0,1)}$
1	1,000	1,000	1,000	0	0	0	0	0	0
2	0,921	0,770	0,766	1	0	1	0	1	0
3	0,892	0,847	0,768	1	0	1	0	1	0
4	0,800	0,829	0,741	0	1	1	0	1	0
5	0,967	0,967	0,964	0	1	1	0	1	0
6	0,986	0,997	1,000	0	1	0	1	0	1
7	1,000	1,000	1,000	0	0	0	0	0	0
8	0,898	0,903	0,868	0	1	1	0	1	0
9	1,000	1,000	1,000	0	0	0	0	0	0
10	0,809	0,764	0,846	1	0	0	1	0	1
11	1,000	1,000	1,000	0	0	0	0	0	0
12	0,884	0,684	0,730	1	0	1	0	0	1
13	1,000	1,000	1,000	0	0	0	0	0	0
14	1,000	1,000	0,996	0	0	1	0	1	0
15	0,975	0,979	0,979	0	1	0	1	0	0

Çizelge 5.5 Her bir test görüntüsü için modellerin PA değerleri ve kıyas örnekleri (Devam)

...
1327	1,000	1,000	1,000	0	0	0	0	0	0
1328	1,000	1,000	1,000	0	0	0	0	0	0
1329	0,843	0,875	0,843	0	1	0	1	1	0
1330	0,872	0,817	0,723	1	0	1	0	1	0
1331	0,943	0,777	0,777	1	0	1	0	1	0
1332	0,764	0,742	0,876	1	0	0	1	0	1
1333	0,662	0,641	0,629	1	0	1	0	1	0
1334	0,855	0,860	0,773	0	1	1	0	1	0
1335	1,000	1,000	1,000	0	0	0	0	0	0
1336	0,971	0,971	0,971	0	0	0	0	0	0
1337	0,974	1,000	1,000	0	1	0	1	0	0
1338	0,885	0,901	0,900	0	1	0	1	1	0
1339	0,974	0,972	0,982	1	0	0	1	0	1
1340	0,767	0,789	0,767	0	1	1	0	1	0
1341	0,872	0,872	0,777	1	0	1	0	1	0
1342	1,000	1,000	1,000	0	0	0	0	0	0
1343	1,000	1,000	1,000	0	0	1	0	1	0
1344	0,834	0,836	0,733	0	1	1	0	1	0
1345	0,948	0,981	0,980	0	1	0	1	1	0

Yukarıda örnekleri sunulduğu şekilde tüm PA değerleri kıyaslanmıştır. $A_{(1,0)}$ değeri karşılaştırılan iki PA değerinde büyükse 1, küçük ise 0 olarak alınmıştır. $A_{(0,1)}$ değeri ise karşılaştırılan iki değerde PA değeri büyükse 0 olarak, küçük ise 1 olarak alınmıştır. Sonuç olarak tüm karşılaştırmalarda 1 değerleri toplanmış ve z değerleri hesaplanmıştır. Hesaplanan z değerleri Çizelge 5.6’da gösterilmiştir.

Çizelge 5.6 Tüm modeller için uygulanan Mc Nemar’s testi sonuçları

	HRNet	PSPNet	U-Net
HRNet		← 3,536	← 18,685
PSPNet			← 15,423
U-Net			

Modellerin karşılaştırılmasında (\leftarrow, \uparrow) okları kullanılmakta ve daha başarılı modeli göstermektedir. Çizelge 4.2’de gösterilmiş olan z değerlerine göre kıyaslama değerlerine göre Çizelge 5.6’da HRNet modeli, PSPNet ve U-Net modellerine kıyasla %99’dan fazla başarı sağlamıştır. PSPNet modeli de U-Net modeline göre daha başarılıdır. Mc Nemar’s testi yukarıda bulunan sonuçların doğruluğunu kanıtlamaktadır.

6. SONUÇ

SAR görüntülerinde bölütlemeye 2 temel sorun bulunmaktadır. Bunlardan birincisi, neredeyse hiç ücretsiz etiketlenmiş veri setinin olmaması, SAR görüntülerinde benek gürültüsünün olması ve görüntü işleme için kullanıma hazır olmamasıdır. Diğeri de SAR görüntülerinde bölütleme konusunda henüz net bir başarının ortaya konulamamasıdır. Yapılan araştırmaların çoğu etiketlenmiş veri setinin nasıl ortaya konulacağından daha çok gözetimsiz öğrenme metotlarını kullanarak yapılmıştır. Gözetimsiz öğrenme modelleri ile yapılan çalışmalar bazı yönleri eksik kalmış ve çok yüksek başarı oranları elde edilememiştir.

Bu çalışmada, yeni bir veri seti yaratma süreci ortaya konulmuş ve oluşturulan bu veri seti, en başarılı derin öğrenme modellerinde kullanılmıştır. En iyi performans HRNet modeli kullanılarak %92.23'lük PA değeri ile elde edilmiştir. Kullanılan modeller ayrıca MC Nemat's testi de kullanılarak değerlendirilmiş ve en iyi performans gösteren model yine HRNet olarak tespit edilmiştir.

Sonuçlar detaylı olarak incelendiğinde şehir alanlarındaki bölütleme başarısının çok düşük olduğu görülmüştür. Tüm alanlara göre şehir alanlarının oranı çok az olduğu için başarı oranı belirli bir seviyede kalmaktadır. Şehir alanlarının bölütlenmesi ayrı olarak yapıldığında başarı oranının artabileceği değerlendirilmektedir.

SAR görüntüleri tüm hava koşullarında çalışabilse de, hava olaylarından görüntünün kalitesi etkilenmektedir. Elde edilen görüntülerde aynı yere ait görüntüler farklı RGB görüntüleriyle ortaya çıkmıştır. Piksel seviyesinde bölütleme yapılırken görüntülerin RGB değerleri çok önemli olduğu için veri setinin artırılması konusunda sıkıntılar yaşanmıştır. Aynı zaman diliminde benzer hava koşullarındaki verileri elde etmek ve onları işlemek bu konuda elde edilen başarının temel etmenlerinden bir tanesidir.

SAR görüntülerinde bölütleme konusunda mutlak bir başarı henüz ortaya konulamamıştır. SAR görüntülerinin gürültülü olması, veri etiketlenmesinde yapılacak hatalar, kullanılan modellerin SAR görüntülerine uygunluğu vb. bu süreci etkileyen temel faktörlerdir. SAR görüntüleri yüksek çözünürlüklü olsa da bölütleme için zor görüntülerdir. İleride yapılan çalışmalarda SAR görüntülerine özel modellerin geliştirilmesinin mutlak başarıyı getireceği değerlendirilmektedir.

Bu alıřmada, yeni bir veri setinin oluřturulmasını detaylı olarak anlatılmıř ve yeni veri seti ile blütleme bařarısı artırılmıřtır. Derin ğrenme modellerinde yksek bařarı saėlayabilmek iin ok byk veri setleri kullanmak gerekse de, ortalama seviyede sayılabilecek grnt sayısıyla eėitim bařarılı bir řekilde yapılmıřtır.



KAYNAKLAR

- Anonim. 2020. Web Sitesi: <https://ayyucekizrak.medium.com/g%C3%B6r%C3%BCnt%C3%BC-b%C3%B6l%C3%BCtleme-segmentasyon-i%C3%A7in-derin-%C3%B6l%C4%9Frenme-u-net-3340be23096b>, Erişim Tarihi: 10.11.2020.
- Anonymous. 2020. Web Sitesi: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>, Erişim Tarihi: 15.08.2020.
- Anonymous. 2020. Web Sitesi: <https://github.com/open-mmlab/mmssegmentation>, Erişim Tarihi: 10.11.2020.
- Anonymous. 2020. Web Sitesi: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes>, Erişim Tarihi: 17.11.2020.
- Bengio, Y. 2012. Practical Recommendations for Gradient-Based Training of Deep Architectures. *Neural Networks: Tricks of the Trade*, 7700, 437-478.
- Bianchi, F.M., Grahn, J., Eckerstorfer, M., Malnes, E. and Vickers, H. 2021. Snow Avalanche Segmentation in SAR Images With Fully Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 75-82.
- Bossard, M., Feranec, J. and Otahel J. 200. CORINE land cover technical guide: Addendum 2000.
- Bostanci, B. and Bostanci, E. 2013. An evaluation of classification algorithms using McNemar's test. *Proceedings of Seventh International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA 2012)*, 15-26, India.
- Bourbigot, M. 2016. Sentinel-1 Product Definition. ESA.
- Buttner, G., Feranec, J., Jaffrain, G., Mari, L., Maucha, G. and Soukup, T. 2004. The CORINE land cover 2000 project,"*EARSeL eProceedings*, 3(3), 331–346.
- Cantorna, D., Dafonte, C., Iglesias, A. and Arcay, B. 2019. Oil spill segmentation in SAR images using convolutional neural networks. A comparative analysis with clustering and logistic regression algorithms. *Applied Soft Computing*, 84, 105716.
- Clauss, K. Ottinger, M. and Kuenzer, C. 2018. Mapping rice areas with Sentinel-1 time series and superpixel segmentation. *International Journal of Remote Sensing*, 39(5), 1399-1420.
- Copernicus. 2020. Web Sitesi: <https://scihub.copernicus.eu>, Erişim Tarihi: 10.10.2020.
- Corine Land Cover. 2020. WEB Sitesi: <https://land.copernicus.eu/pan-european/corine-land-cover> , Erişim Tarihi: 10.11.2020.

- Curlander, J.C., McDonough R.N. 1991. Synthetic Aperture Radar. Wiley, 672. New York.
- Ding, Y., Li, Y. And Yu, W. 2014. SAR image classification based on CRFs with integration of local label context and pairwise label compatibility. IEEE J. Sel. Topics Appl. Earth Obs. Remote Sensing, 7, 300-306.
- Dirk, G., Ramón, T., Paul, S., Malcolm, D. and Björn, R. 2014. Sentinel-1 System capabilities and applications, IEEE Geoscience and Remote Sensing Symposium, 13-18 Temmuz, 1457-1460, Quebec City, Canada.
- Ebrahimi, A., Helfroush, M. S., Danyali, H., and Bazrafkan, S. 2014. Contourlet-based level set SAR image segmentation. Artificial Intelligence and Signal Processing Communications in Computer and Information Science, 247, 51–59.
- Fariba M., Bahram S., Masoud M., Gillb, E., Molinier, M. 2019. A new fully convolutional neural network for semantic segmentation of polarimetric SAR imagery in complex land cover ecosystem. International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS), 151, 223-236.
- Federico, F. 2019. Sentinel-1 GRD Preprocessing Workflow. 3rd International Electronic Conference on Remote Sensing, Proceedings, MDPI, 22 Mayıs – 5 Haziran, Proceedings, 18(1), 11, Roma, Italy.
- Feng, J., Cao, Z., and Pi, Y. 2012. Variational SAR image segmentation based on the G0 model and an augmented Lagrangian method. Progress in Electromagnetics Research B, 39, 373–392.
- Feng, J., Jiao, L.C., Zhang, X., Gong, M., and Sun, T. 2013. Robust non-local fuzzy c-means algorithm with edge preservation for SAR image segmentation. Signal Processing, 93, 487–499.
- Henry, C., Azimi, S. M., Merkle, N. 2018. Road Segmentation in SAR Satellite Images with Deep Fully-Convolutional Neural Networks. IEEE Geoscience and Remote Sensing Letters, 15, 1867-1871.
- Huang, L., Liu, B., Li, B., Guo, W., Yu, W., Zhang, Z. and Yu W. 2018. OpenSARShip: A Dataset Dedicated to Sentinel-1 Ship Interpretation. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11(1), 195-208.
- Irak, H. 2009. SAR Sistem ve Teknolojileri. Elektrik Mühendisliği, 437, 86-90.
- Jiao, L.C., Gong, M.G. and Wang, S. 2010. Natural and Remote Sensing Image Segmentation Using Memetic Computing. IEEE Comp. Int. Mag., 5(2), 78-91.
- Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P. 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.

- Kaushik, R. and Kumar, S. 2019. Image Segmentation Using Convolutional Neural Network. *International Journal Of Scientific & Technology Research*, 8(11), 667-675.
- Machine Learning Mastery. 2019. <https://machinelearningmastery.com/pooling-layers-for-convolutional-neural-networks/>. Eriřim Tarihi: 22.05.2021
- Malmgren-Hansen, D. and Nobel-Jorgensen, M. 2015. Convolutional neural networks for SAR image segmentation. *IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, 231-236.
- Martin, S. 2004. *Introduction to Ocean Remote Sensing*. Cambridge University Press, 511, United Kingdom UK.
- McNemar, Q. 1947. Note on the sampling error of the difference between correlated proportions or percentages. *Psychometrika* 12, 153–157.
- Natteshan, N.V.S. and Kumar, N.S. 2020. Effective SAR image segmentation and classification of crop areas using MRG and CDNN techniques. *European Journal of Remote Sensing*, 53, 126-140.
- O'Donnell, R.M. 2009. *Radar Systems Engineering Lecture 18 SAR*. IEEE, New Hampshire.
- Ronneberger, O., Fischer, P. and Brox, T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation, In: *Medical Image Computing and Computer-Assisted Intervention-2015*. Navab, N. and Hornegger, J. (eds), Springer International Publishing, 234-241, Cham.
- Őćepanović, S., Antropov, O., Laurila, P., Rauste, Y., Ignatenko, V. And Praks, J. 2021. Wide-Area Land Cover Mapping with Sentinel-1 Imagery using Deep Learning Semantic Segmentation Models.
- Shang, R., Chen, C., Wang, G., Jiao, L., Okoth, M.A. and Stolkin, R. 2020. A thumbnail-based hierarchical fuzzy clustering algorithm for SAR image segmentation. *Signal Processing*, 171, 107518.
- Shang, R., Lin, J., Jiao, L. and Li, Y. 2020. SAR Image Segmentation Using Region Smoothing and Label Correction. *Remote Sensing*, 12(5), 803.
- Sharma, S., Sharma, S. and Athaiya, A. 2020. Activation Functions In Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310-316.
- Shimada, M., Itoh, T., Motoooka, T., Watanabe, M., Shiraishi, T., Rajesh Thapa, R. And Lucas, R. 2014. New global forest/non-forest maps from ALOS PALSAR data (2007–2010). *Remote Sensing of Environment*, 155, 13-31.

- Soumekh, M. 1999. Synthetic aperture radar signal processing with MATLAB algorithms. Wiley, 616. New York.
- Srivastava, N., Hinton, G.E., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. 2014. Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15(1), 1929-1958.
- Sun, K., Zhao, Y., Jiang B., Cheng, T., Xiao, B., Liu, D. Mu, Y., Wang, X., Liu, W. And Wang, J. 2019. High-Resolution Representations for Labeling Pixels and Regions. *CoRR*, abs/1904.04514.
- Tan, W., Li, J., Xu, L. and Chapman, M.A. 2018. Semiautomated Segmentation of Sentinel-1 SAR Imagery for Mapping Sea Ice in Labrador Coast. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1419-1432.
- Ünlü, E.I. 2019. Derin Öğrenme İle Görüntü Bölütleme. Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Yazılım Anabilim Dalı, 64, Elazığ.
- Wang, X., Cagielli, L. and Eggimann, M. 2020. Hr-sar-net: A Deep Neural Network for Urbanscene Segmentation From High-resolution SAR Data. *IEEE Sensors Applications Symposium, SAS, IEEE*, 9-11 Mart, Kuala Lumpur, Malaysia.
- Wang, Y. and Zhu, X.X. 2018. The SARptical Dataset for Joint Analysis of SAR and Optical Image in Dense Urban Area. *IGARSS, IEEE International Geoscience and Remote Sensing Symposium*, 22-27 Temmuz, Valencia, Spain.
- Wei, S., Zeng, X., Qu, Q., Wang, M., Su, H. and Shi, J. 2020. HRSID: A High-Resolution SAR Images Dataset for Ship Detection and Instance Segmentation. *IEEE*, 8, 120234-120254.
- Wikipedia. 2020. Web Sitesi: https://en.wikipedia.org/wiki/Synthetic_aperture_radar , Erişim Tarihi: 10.12.2020
- Wiley, C.A. 1985. Synthetic Aperture Radars. *IEEE*, 21(3), 440-443.
- Wu, W., Li, H., Li, X., Guo, H., Zhang, L. 2019. PolSAR Image Semantic Segmentation Based on Deep Transfer Learning—Realizing Smooth Classification With Small Training Sets. *IEEE Geoscience and Remote Sensing Letters*, 16(6), 977–981.
- Yumus, D. 2019. Land Cover Classification For SAR Imagery Using Unsupervised Methods. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Mühendisliği Anabilim Dalı, 143, Ankara.

- Zeng, K., Ma, Y., Ding, X., and He, M. 2014. An adaptive threshold segmentation algorithm to extract dark targets from SAR images. IEEE International Geoscience and Remote Sensing Symposium, 13-18 Temmuz, 1765–1768, QC, Kanada.
- Zhang, P., Li, M., Wu, Y., Liu, G., Chen, H., and Jia, L. 2013. Unsupervised SAR image segmentation using a hierarchical TMF model. IEEE Geoscience and Remote Sensing Letters, 10, 971–975.
- Zhao, H., Shi, J., Qi, X., Wang, X. and Jia, J. 2017. Pyramid Scene Parsing Network. Proceedings the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2881-2890
- Zhu, X.X., Montazeri, S., Ali, M., Hua, Y., Wang, Y., Mou, L., Shi, Y., Xu, F. and Bamler, R. 2021. Deep Learning Meets SAR. IEEE Geoscience and Remote Sensing Magazine, 2006.10027.