



**ARAZİ ÖRTÜSÜ VE KULLANIMI İÇİN SAR
GÖRÜNTÜLERİNİN SINIFLANDIRILMASINDA
TOPLULUK ÖĞRENME TABANLI YAKLAŞIM**

**2023
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Elif MEŞECİ

**Tez Danışmanı
Doç. Dr. Caner ÖZCAN**

**ARAZİ ÖRTÜSÜ VE KULLANIMI İÇİN SAR GÖRÜNTÜLERİNİN
SINIFLANDIRILMASINDA TOPLULUK ÖĞRENME TABANLI
YAKLAŞIM**

Elif MEŞECİ

**Tez Danışmanı
Doç. Dr. Caner ÖZCAN**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Ağustos 2023**

Elif MEŞECİ tarafından hazırlanan “ARAZİ ÖRTÜSÜ VE KULLANIMI İÇİN SAR GÖRÜNTÜLERİNİN SINIFLANDIRILMASINDA TOPLULUK ÖĞRENME TABANLI YAKLAŞIM” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Caner ÖZCAN

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 28/08/2023

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Sait DEMİR (KBÜ)

Üye : Doç. Dr. Caner ÖZCAN (KBÜ)

Üye : Dr. Öğr. Üyesi Sevdanur GENÇ (KÜ)

ONLINE

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onaylamıştır.

Doç. Dr. Zeynep ÖZCAN

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Elif MEŞECİ

ÖZET

Yüksek Lisans Tezi

ARAZİ ÖRTÜSÜ VE KULLANIMI İÇİN SAR GÖRÜNTÜLERİNİN SINIFLANDIRILMASINDA TOPLULUK ÖĞRENME TABANLI YAKLAŞIM

Elif MEŞECİ

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. Caner ÖZCAN

Ağustos 2023, 43 sayfa

Sentetik açıklıklı radar (SAR), yüksek çözünürlüklü görüntü elde etmek için büyük anten yerine anten dizisi kullanma fikrine dayanan uzaktan algılama sistemidir. Yeryüzünün coğrafi, biyolojik ve fiziksel incelemeleri için su kaynaklarının, yeşillik alanların gelişmelerinin izlenmesi, yeryüzü şekillerindeki değişimlerin takibi gibi uygulamalarda SAR görüntülerinden yararlanılmaktadır. Gelişen teknoloji, birçok yüksek boyutlu SAR görüntüsünün kaydedilmesine ve yorumlanmasına olanak sağlamaktadır. Ancak veri boyutlarının büyümesi nedeniyle öznitelikler artmakta ve analiz zorlaşmaktadır. Bu nedenle, otomatik özellik çıkarımı yapabilen derin öğrenme algoritmalarına ihtiyaç duyulmaktadır. Önerilen bu çalışmada, SAR görüntülerinin derin öğrenme modelleri kullanılarak beş sınıfa ait farklı arazi örtüsü ve kullanımının topluluk öğrenme tabanlı bir yaklaşım ile sınıflandırılması sağlanmıştır. Algoritma çalışma süresi minimum seviyede tutularak sınıflandırma performansının artırılması

için yoğun bağlantıların ve transfer öğrenme yöntemlerinin avantajları bir araya getirilerek yeni bir yöntem geliştirilmiştir. Geliştirilen yöntem hızlı ve yüksek doğrulukta görüntülerin sınıflandırılmasını sağlamaktadır. Bu yöntem, yüksek performans sergileyen derin öğrenme modelleri ve ilave katmanların bir araya geldiği bir yapıya sahiptir. Bu yapı, topluluk öğrenme yaklaşımını benimseyerek, hem doğruluk hem de performans açısından artış sağlamaktadır. Ayrıca oluşturulan modelde güncellenen parametre sayısı azaltılarak modelin gereksiz özellikleri öğrenmesinden kaçınılmış ve bu sayede yüksek performans sağlanmıştır.

Deneysel çalışmalar kapsamında SAR görüntülerinde çevresel faktörlerden kaynaklı olarak var olan benek gürültüsünün de ele alındığı analizler gerçekleştirilmiştir. Görüntülerdeki kenar ve noktasal saçıcıların bozulmasını önleyerek homojen bölgelerin yumuşatılmasını sağlayan seyreklik güdümlü benek azaltma (SDD) filtresi kullanılarak gürültü probleminin önüne geçilmiş ve arazi örtüsü ve kullanımının sınıflandırılması yüksek başarımla gerçekleştirilmiştir. Çalışmada, SAR görüntülerinde arazi örtüsü ve kullanımı farklı derin öğrenme yöntemleri ile sınıflandırılarak ele alınmıştır ve kapsamlı olarak incelenmiştir. Önerilen SAR DenseNet-tabanlı Topluluk Öğrenme Ağı (SARDE-Net), yakın tarihli literatürdeki diğer derin öğrenme sınıflandırıcıları ile karşılaştırılmış ve %98,77 doğruluk, %98,81 kesinlik, %98,64 duyarlılık ve %98,72 f1-skoru metrikleri ile en yüksek sonuçları elde etmiştir. Önerilen modelin karmaşık görüntüler içeren büyük veri kümelerine de uygulanabileceği doğrulanmıştır.

Anahtar Sözcükler : Sentetik Açıklıklı Radar (SAR), uzaktan algılama, derin öğrenme, benek giderme, arazi örtüsü, arazi kullanımı, sınıflandırma.

Bilim Kodu : 92431

ABSTRACT

M. Sc. Thesis

ENSEMBLE LEARNING-BASED APPROACH TO CLASSIFICATION OF SAR IMAGES FOR LAND COVER AND USE

Elif MEŞECİ

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Assoc. Prof. Dr. Caner ÖZCAN

August 2023, 43 pages

Synthetic Aperture Radar (SAR) is a remote sensing system based on the idea of using an antenna array instead of a large antenna to obtain high resolution images. SAR images are used for geographical, biological and physical investigations of the earth in applications such as monitoring the development of water sources, vegetation areas and tracking changes in landforms. Developing technology enables the recording and interpretation of many high-dimensional SAR images. However, as the data size grows, the number of features increases and analysis becomes difficult. Therefore, there is a need for deep learning algorithms that can perform automatic feature extraction. In this proposed study, an ensemble learning based approach is used to classify five classes of different land cover and land use using deep learning models of SAR images. A new method is developed by combining the advantages of dense connections and transfer learning methods to improve classification performance while minimizing algorithm runtime. The proposed method provides fast and highly

accurate image classification. This method has a structure that combines high-performing deep learning models and additional layers. By adopting an ensemble learning approach, this structure increases both accuracy and performance. In addition, by reducing the number of parameters updated in the model, the model avoids learning unnecessary features and thus achieves high performance.

Within the scope of the experimental studies, the speckle noise in SAR images due to environmental factors was also analyzed. By using a sparsity-driven despeckling (SDD) filter, which smoothes homogeneous regions by preventing the distortion of edge and point scatterers in the images, the noise problem is avoided and the classification of land cover and use is performed with high success. In this study, land cover and use in SAR images are analyzed in detail by using different deep learning methods. The proposed SAR DenseNet-based Ensemble Learning Network (SARDE-Net) was compared with other deep learning classifiers in recent literature and achieved the highest results with 98.77% accuracy, 98.81% precision, 98.64% recall and 98.72% f1-score metrics. It is verified that the proposed model can be applied to large datasets containing complex images.

Key Word : Synthetic Aperture Radar (SAR), remote sensing, deep learning, despeckling, land cover, land use, classification.

Science Code : 92431

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Do. Dr. Caner ÖZCAN'a sonsuz teőekkürlerimi sunarım.

alıőmam boyunca tecrübeleri ile bana ışık tutan ve her zaman cesaretlendirici yaklaőımı ile destek olan Öğr. Gör. Buse Yaren KAZANGİRLER'e, her zaman yanımda olarak beni ve alıőmalarımı destekleyen Dilara ÖZDEMİR'e, yardımlarını esirgemeyen Muhammet DİLMA'a ve teővik eden yaklaőımı ile bana destek olan Süheda AKDAĞ'a teőekkür ederim.

Ek olarak bu tez alıőmasını "KBÜBAP-23-YL-027" proje numarası ile desteklemeye layık gören Karabük Üniversitesi Bilimsel Araőtırma Projeleri Koordinasyon Birimi'ne teőekkürlerimi sunarım.

Sevgili aileme tüm hayatım boyunca beni destekledikleri ve her zaman beni daha ok alıőmaya teővik ettikleri için tüm kalbimle teőekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
KISALTMALAR	xiv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	7
SAR GÖRÜNTÜLEME VE VERİ SETİ	7
2.1. SAR GÖRÜNTÜLEME.....	7
2.2. ÇALIŞMA ALANI VE VERİ SETİ	8
2.3. ÖN İŞLEMLER.....	10
2.3.1. Benek Gürültüsü Azaltma	10
2.3.2. Veri Artırma.....	12
BÖLÜM 3	14
EVRİŞİMLİ SİNİR AĞLARI	14
3.1. ALEXNET.....	14
3.2. VGG-16.....	16
3.3. GOOGLNET	17
3.4. RESNET	18
3.5. MOBILENET	20

3.6. EFFICIENTNET	20
3.7. DENSENET	21
BÖLÜM 4	23
SARDE-NET TOPLULUK ÖĞRENME MODELİ	23
BÖLÜM 5	28
SAR GÖRÜNTÜLERİNDE ARAZİ ÖRTÜSÜ VE KULLANIMININ SINIFLANDIRILMASI.....	28
5.1. PERFORMANS ÖLÇÜM METRİKLERİ.....	29
5.2. K-KAT ÇAPRAZ-DOĞRULAMA	31
5.3. SARDENET	32
5.4. SDD FİLTRESİNİN PERFORMANSA ETKİSİ.....	34
5.5. CNN MODELLERİ İLE KARŞILAŞTIRMA.....	35
BÖLÜM 6	36
SONUÇLAR VE ÖNERİLER	36
KAYNAKLAR	38
ÖZGEÇMİŞ	43

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1 SAR görüntüleme sistemi.	8
Şekil 2.2. Hindistan'daki Visakhapatnam Limanı.	9
Şekil 2.3. Veri setini oluşturan sınıfların örnek olarak görselleştirilmesi.....	9
Şekil 2.4. Orijinal görsel ve filtrelenmiş görsellerin örneklendirilmesi.....	11
Şekil 2.5. Veri artırımı.	13
Şekil 3.1. AlexNet modelinin katmanlarının yapısal gösterimi.	15
Şekil 3.2. VGG modelinin katmanlarının yapısal gösterimi.	17
Şekil 3.3. GoogleNet modelinin katmanlarının yapısal gösterimi.	18
Şekil 3.4. ResNet modelinin katmanlarının yapısal gösterimi.	19
Şekil 3.5. MobileNet modelinin katmanlarının yapısal gösterimi.	20
Şekil 3.6. EfficientNet modelinin katmanlarının yapısal gösterimi.	21
Şekil 3.7. DenseNet modelinin katmanlarının yapısal gösterimi.	22
Şekil 4.1. Birleştirilen modellerin yapısal gösterimi.....	24
Şekil 4.2. SARDE-Net model mimarisi	27
Şekil 5.1. SARDE-Net modelinin sınıflandırma çıktılarının örneklendirilmesi.....	33

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. SARDE-Net mimarisinin bileşenleri olarak kullanılan ağlara ait parametreler.....	25
Çizelge 4.2. SARDE-Net mimarisine ait parametreler.	25
Çizelge 5.1. Karmaşıklık matrisi.....	29
Çizelge 5.2. Çok sınıflı sınıflandırma karmaşıklık matrisi.	30
Çizelge 5.3. 5-kat çapraz doğrulama sonucu.	31
Çizelge 5.4. SARDE-Net mimarisinin sınıf bazlı sınıflandırma sonuçları.	32
Çizelge 5.5. Orijinal ve filtreli görüntülerin sınıf bazlı sınıflandırma sonuçları.....	34
Çizelge 5.6. Sınıflandırma modellerinin performans değerleri.....	35

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

- λ : yumuŖatma seviyesi
F : gürültüsü azaltılmıŖ görüntü
G : benek gürültülü görüntü
p : piksel indisi

KISALTMALAR

CNN	: Convolutional Neural Networks (Evrifimli Sinir Ađları)
DNN	: Deep Neural Networks (Derin Sinir Ađları)
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması)
MBCConv	: Mobile-inverted Bottleneck Convolution (Mobil Ters Darboğaz Evrifim)
ReLU	: Rectified Linear Unit (Doğrultulmuş Lineer Birim)
SAR	: Synthetic Aperture Radar (Sentetik Açıklıklı Radar)
SARDE-Net	: SAR DenseNet-based Ensemble Network (SAR DenseNet-Tabanlı Topluluk Öğrenme Ađı)
SDD	: Sparsity Driven Despeckling (Seyreklik-Güdümlü Benek Gürültü Azaltma)
VGG	: Visual Geometry Group (Görsel Geometri Grubu)

BÖLÜM 1

GİRİŞ

Uzaktan algılama, son yıllarda arazi kullanımı ve arazi örtüsü haritaları üretmek için önemli standart bir araç olmuştur. Uzaktan algılama sistemleri, kullanılan enerji kaynaklarına göre aktif ve pasif algılama sistemleri olmak üzere ikiye ayrılmaktadır. Herhangi bir enerji üretilmeyen pasif algılama sistemlerinde güneş enerjisi kullanılmaktadır. Aktif algılama sistemlerinde ise kendi ihtiyacı olan enerji, sistem tarafından üretilmektedir [1]. Bu sistemde, kaynaktan yansıtılan enerjinin hedeften dönen yansımaları toplanarak görüntü elde edilmektedir. Bu sayede aktif algılama sistemleri, pasif sistemlerin aksine olumsuz hava koşullarından etkilenmeden görüntü sağlayabilmektedir. Aktif uzaktan algılama sisteminde önemli örneklerden biri Sentetik Açıklıklı Radar (Synthetic Aperture Radar, SAR)'dır ve bu tez çalışmasında SAR görüntüleri üzerinde çalışılmıştır.

SAR, optik verilere kıyasla hava koşulları gibi faktörlerden etkilenmediği için yer formlarının görüntülenmesinde yaygın olarak tercih edilen bir sistemdir [2]. SAR, çoklu radar birimleri ile toplanan görüntüleri elektronik ortamda birleştirir. Bu kombinasyon, SAR görüntülerinde, tek seferde bir radar ünitesi tarafından elde edilen büyük görüntülerden daha yüksek bir çözünürlük sağlar. Ayrıca, gece ve gündüz zaman dilimlerinde ışıktan etkilenmeden görüntüleme yapabilmektedir. SAR, görüntüleme sürecinde tüm bu koşullara uyum sağlayarak birçok avantaj sağlasa da analiz süreci diğer uzaktan algılama cihazlarından elde edilen görüntülere göre daha zordur [3]. Dünya üzerindeki geniş alanlarda SAR tarafından yakalanan nesnelere, geri saçılan elektromanyetik dalganın yoğunluğu tarafından yansıtılmaktadır. Geniş alanlarda görüntüleme sağlayabilen SAR, tespit edilebilir nesnelere sayısını artırırsa da yansıyan nesnelere ayırt edilmesi gerçek görünümünden daha zordur. Bu nedenle tespit süreci de karmaşıktır ve bu aşamada uzmanlara ihtiyaç vardır. Uzaktan algılama uygulamalarında, ilgi duyulan sınıflar için yeterli sayıda etiketli veriye sahip olmak

hem zorlu bir süreçtir hem de hatalara oldukça açıktır. [4]. Öte yandan, geniş alanları kapsayan SAR görüntülerinde insan gözü ile nesne tespiti ve analizi yapmak oldukça zaman alıcıdır. Bu gibi durumlarda analiz sürecini otomatikleştirerek zaman verimliliği sağlayan derin öğrenme yöntemlerine ihtiyaç bulunmaktadır.

Derin öğrenme algoritmaları, otomatik özellik çıkarımı sayesinde görüntülerin sınıflandırılması ve nesne tespiti için klasik makine öğrenmesi yöntemlerine göre son yıllarda oldukça fazla tercih edilmektedir [5–7]. Yapay sinir ağlarında katmanların derinleştirilmesiyle oluşturulan Derin Sinir Ağları (Deep Neural Networks, DNN) [8], karmaşık verilerin matematiksel modelleme ile işlenmesini sağlar. DNN içerisinde yer alan Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN) [9], görüntülerin matematiksel verilerine konvolüsyon fonksiyonunu uygulayarak görüntü analiz sürecinde başarı elde etmektedir. İleri beslemeli bir ağ olan CNN, sahip olduğu havuzlama katmanı sayesinde farklı boyutlarda girdiler alan model mimarilerindeki hesaplama karmaşıklığı ve yüksek boyutluluk sorunlarına çözüm sunabilmektedir. Başka bir deyişle, CNN diğer DNN modellerine göre daha az eğitim ve parametre kullanarak görüntü sınıflandırmasını başarılı bir şekilde gerçekleştirebilmektedir [10]. CNN modelleri bu avantajları sayesinde SAR görüntülerinin sınıflandırılmasında ve SAR görüntüleri üzerindeki nesnelere tespitinde de kullanılmaktadır. CNN modellerinin nispeten karmaşık SAR sinyallerini çözmek için mükemmel bir şekilde uygun olduğu ve bu nedenle uzun vadede nesne tespiti, arazi örtüsü sınıflandırması, değişim tespiti gibi bir çok alanda önemli bir rol oynayacağı varsayılmaktadır [11].

Yapılan bir çalışmada El Housseini vd. [12], SAR görüntülerinde askeri araçları tanımak için derin öğrenme mimarisini kullanan otomatik hedef tanıma sistemi önermiştir. Sistemin optimizasyonu için evrişimli otomatik kodlayıcı kullanılmasının daha iyi sonuçlar verebileceğini vurgulamıştır. Furukawa [13], SAR görüntülerinde otomatik bir hedef tanıma sistemi önermiştir. Yaptığı çalışmada CNN dönüşüm değişmezliğini incelemiş ve veri artırmanın önemini vurgulamıştır. Yapılan çalışmanın uzaysal-zamansal sentetik açıklıklı radar görüntülerinin analizinde büyük önem taşıdığı belirtilmiştir. Wang vd. [14], çift aşamalı birleşik CNN mimarisine sahip derin ağ tabanlı bir hedef tanıma sistemi önermiştir. Bu yöntem bir benek gürültüsü giderme alt ağı ve bir sınıflandırma alt ağından oluşmaktadır. Yöntemdeki

sınıflandırma alt ağı, benek gürültüsü giderme alt ağından gelen SAR görüntülerini kullanarak hem hedefin hem de kalıntı beneklerin özelliklerini öğrenebileceğini öne sürmüştür.

Wang vd. [15], SAR görüntüleri üzerinde gemi sınıflandırma görevi için yaptıkları çalışmada transfer öğrenme yaklaşımının kullanılması ile küçük veri seti kullanıldığında bile başarımların sağlanabileceğini göstermiştir. Yine küçük veri seti ile çalışma yapan Lu ve Li [16], küçük veri setlerinin eğitilmesinde sıklıkla ortaya çıkan aşırı uyum sorununu çözmek için yeni bir veri artırma yöntemi önermiş ve bunu transfer öğrenme ile birleştirmiştir. Wu vd. [17], küresel muhakeme modülü ve maske destekli bir gemi algılama modülü kullanan SAR görüntülerinde bir gemi algılama sistemi önermiştir. Sun vd. [18], gemileri görüntüdeki saçılma özelliklerine göre tanıyan bir ağ tasarlamıştır. Gemi alanında var olan güçlü saçılma noktalarını yakalayan güçlü saçılma noktası farkındalıklı bir ağ kullanarak sınıflandırma yaklaşımı ile önemli bir ilerleme kaydedilmiştir.

Yaohua ve Xudong [19], petrol sızıntılarının tespiti için DenseNet modelinin etkinliğini incelemiştir. Yaptıkları çalışmada, DenseNet modelinin yoğun katmanlarının etkisinin yanı sıra görüntülere uyguladıkları benek azaltma filtresinin etkisi ile modelin performansını artırmışlardır. Bianchi vd. [20], dünya çapındaki petrol sızıntılarını tespit etmek ve sınıflandırmak için derin bir öğrenme yöntemi geliştirmiştir. Bu sistem için U-Net tabanlı Oil Free ConvNet adlı bir bölütleme mimarisi önermiştir. Aghaei vd. [21], geliştirdikleri Osdes-Net mimarisine eklemek üzere birbirinden farklı altı blok geliştirmiştir. Bu blokların her birini ana model ile birleştirerek petrol sızıntısı, kara, gemi ve deniz yüzeyi alanlarının sınıflandırılması üzerindeki başarısını test etmiştir. Chen vd. [3], özellik eşleme için bölge öneri ağı ile çok çözünürlüklü dikkat ve denge ağı adlı yeni bir derin öğrenme yaklaşımı kullanarak SAR görüntülerinde bir köprü algılama sistemi önermiştir.

SAR geri saçılımının bitki örtüsü gibi yapısal özelliklere duyarlı olması ve gönderilen dalgaların bulutlara nüfuz etmesi, büyük ölçekli değerlendirmeler için uygun hale getirmektedir [22]. Bu bağlamda, SAR verileri sıklıkla arazi örtüsü ve bitki örtüsü tipi sınıflandırma görevleri için CNN modellerinde veri olarak kullanılmaktadır. Li vd.

[23], optik ve SAR görüntüleri üzerinde arazi kullanımı sınıflandırması için anlamsal bir bölütleme çerçevesi önermiştir. Wu vd. [2], otomatik kodlayıcı düzenleme ve bağlamsal dikkat kolu olmak üzere iki aşamadan oluşan MCAR-CAN mimarisini önermiştir. Bu mimari ile literatüre farklı bir yaklaşım sunulmuş olsa da sonuçlar yeterince iyileştirilememiştir. Pradhan vd. [24], Word2Vec modelinden öğrenilen sınıf özelliklerini, hem ilk aşamada kullanılan tek katmanlı CNN tarafından çıkarılan özellikleri hem de eğitim sırasında sınıf özelliklerini ve tahmin sırasında yalnızca özellikleri kullanarak sınıf ataması tahmini yapan ikinci bir CNN modeli kullanarak Zero-Shot Learning yaklaşımı kullanmıştır. Huang vd. [25], optik arazi örtüsü veri seti ile ResNet modeline dayanan bir derin transfer öğrenme yöntemi önermiştir. Bu çalışmada, etiket gürültüsü ve dengesiz sınıf sorunlarının üstesinden gelmek için maliyete duyarlı parametrelere sahip bir kayıp fonksiyonu tanıtılmıştır. Liang vd. [26], çok ölçekli derin özellik füzyon ağı ve çok katlı kovaryans havuzlama ağı kullanarak yeni bir yüksek çözünürlüklü SAR görüntü sınıflandırma yöntemi önermiştir. Bu yöntem, yerel uzamsal özelliklerin ve küresel istatistiksel özelliklerin avantajlarını birleştirmiştir. Li vd. [23], sözde siyam özellik çıkarımı, çok modlu çapraz dikkat ve düşük-yüksek seviye özellik füzyon modüllerinden oluşan bir çok modlu-çapraz dikkat ağı geliştirmiştir. Bu çalışma SAR görüntülerinde arazi örtüsü ve kullanımının bölütlenmesi görevi için önemli bir çalışma olmuştur. Kang vd. [27], arazi örtüsü sınıflandırma görevi için omurga ağı olarak MobileNet içeren bir çapraz kaynaştırma modeli geliştirmiştir. Çalışmada kullanılan optik ve SAR görüntülerinin birbirini tamamlayıcı özelliklere sahip olduğu öne sürülmüştür.

Arazi kullanımı ve arazi örtüsü sınıflandırması, kentsel planlama, tarım alanlarının yönetilmesi, doğal afetlerin yönetimi, yolların planlanması gibi alanlarda gerekli bilgilerin elde edilebilmesi konusunda önem taşımaktadır. Uzaktan algılamadaki uygulamasının benzersizliği nedeniyle, özellikle sınıflandırma uygulamalarının daha da geliştirilmesi ve araştırılması gerekmektedir [28]. Uzaktan algılama yöntemleri ile elde edilen görüntülerde ele alınan sınıflara benzer saydamlık ve spektral değerlere sahip çeşitli engel türlerinin varlığı nedeniyle, sınıflandırma ve bölütleme yöntemleri kullanılarak sınıfların doğru çıkarımını elde etmek hala zordur [29]. Arazi örtüsü ve arazi kullanımına ait sınıflar arası benzerlik ve sınıf içi heterojenlik nedeniyle arazi

kullanımının özellikleri henüz çözülememiştir [4]. Tüm bu durumlar doğrultusunda bu tez çalışması literatürdeki önemli bir açığa çözüm sunmaktadır.

Bu tezin amacı, SAR görüntüleri üzerinde su, bina, bitki örtüsü, yol ve kıyı yer şekilleri olmak üzere beş sınıfa ait farklı arazi kullanımı ve arazi örtüsünün sınıflandırılması görevi için derin öğrenme algoritmalarına dayalı bir SAR DenseNet-Tabanlı Topluluk Öğrenme Ağı (SAR DenseNet-based Ensemble Network, SARDE-Net) modeli önermektir. Çalışmada kullanılan 22000x19000 boyutlarındaki SAR görüntüsü kamuya açık TerraSAR-X spotlight görüntü arşivinden [30] alınmıştır. Daha sonra, yüksek boyutlu ve geniş alanlı SAR görüntüsü, ayırt edici ve bağımsız özelliklere sahip 100x100 yamaya bölünmüştür. Kırpılan görüntüler yama tabanlı yaklaşım ile beş sınıfa ayrılmıştır. Yama tabanlı bölünmüş görüntüler derin öğrenme ağına aktarılmadan önce, Seyreklik-Güdümlü Benek Gürültü Azaltma (Sparsity Driven Despeckling, SDD) [31] ile benek gürültüsü filtrelemesi uygulanmıştır. SDD filtresi, SAR görüntülerinde ışık gibi doğal faktörlerin neden olduğu gürültüyü ortadan kaldırır. Su, bina, bitki örtüsü, yol ve kıyı sınıflarına ait gürültüsü azaltılmış görüntülerin tanınması için bir sistem geliştirilmiştir. Bu çalışmada önerilen yöntemin amacı, literatürde yaygın olarak kullanılan derin öğrenme modellerinin SAR görüntüleri üzerindeki performansını analiz ederek iyileştirilmiş bir topluluk öğrenme modeli geliştirmektir. Bu çalışmanın temel katkısı ve yeniliği aşağıdaki gibi özetlenebilir:

- Bu çalışmada görüntüler küçük yamalara bölünmüş ve daha fazla sayıda ve daha fazla ayrıntıya sahip görüntüler kullanılarak sınıflandırma yapılmıştır. Yama tabanlı yaklaşım, görüntülerin uzaktan elde edilmesinden kaynaklanan uzaysal çözünürlük sorununa bir çözümdür.
- Literatürdeki çalışmalar SAR görüntülerinde saçılmadan kaynaklanan benek gürültüsünün sınıflandırıcı performansını olumsuz etkilediğini göstermiştir. Bu çalışmada, benek gürültüsünü gidermek için SDD filtresi uygulanmış ve performans iyileştirilmiştir.
- SAR görüntüleri üzerinde birden fazla derin öğrenme modeli kullanarak detaylı sınıflandırma yapan çalışmaların yeterli düzeyde olmadığı gözlemlenmiştir. Çalışma kapsamında derin öğrenme modellerinin

karşılaştırılması yapılmış ve yüksek performans gösteren modeller kullanılarak bir topluluk öğrenme modeli oluşturulmuştur.

- Hiper-parametre ayarlarının uygulanması ve kullanılan derin öğrenme ağlarının ince ayarının yanı sıra, performansı artırmak için model yapısı değiştirilmiştir.
- Tasarlanan modellerin çalışma süresi optimize edilmiştir. Topluluk modeli oluşturulurken parametre sayısı önemli ölçüde azaltılmıştır. Bu şekilde, model hesaplama karmaşıklığı ve maliyeti azaltılmış olmaktadır.

BÖLÜM 2


SAR GÖRÜNTÜLEME VE VERİ SETİ

SAR görüntüleme, elektromanyetik dalgaların yansınmasıyla nesnelerin konumlarını ve özelliklerini belirlemek amacıyla kullanılan bir uzaktan algılama tekniğidir. Hava koşulları ve güneş ışığı gibi etmenlerden etkilenmemesi ve yüksek çözünürlüklü radar görüntü üretme yeteneği sayesinde birçok alanda çalışmaların ortak noktası haline gelmiştir. Ancak bu avantajlarının yanı sıra benek gürültüsü oluşumu dezavantajına sahiptir. SAR görüntüleri kendine özgü, çarpımsal özellikte ve rastgele yapıya sahip benek gürültüsü içermektedir. Benek gürültüsü oluşan alanlarda ince detay özelliklerin tespit edilebilirliği üzerinde olumsuz etkilere sebep olmaktadır. Bu bağlamda, SAR görüntüleri üzerinde sınıflandırma, nesne tespiti gibi çalışmalar yapılmadan önce bu benek gürültülerinin giderilmesi önem arz etmektedir. Bu bölümde, SAR görüntüleme, çalışmada kullanılan veri setinin oluşturulması ve ön işlemler detaylı olarak anlatılmaktadır.

2.1. SAR GÖRÜNTÜLEME

Uzaktan algılama alanında sağladığı birçok avantaj sayesinde sıklıkla kullanılan SAR, nesnelerin görüntülerini oluşturmak için birden fazla küçük radar anteni tarafından toplanan radar görüntülerinin birleştirilmesiyle elde edilen radar çeşididir. SAR görüntüleme sistemi, yüksek çözünürlüğe ulaşmak için büyük anten yerine anten dizisi kullanma fikrine dayanmaktadır. Bu anten dizisi, fiziksel olarak birden çok antenin yan yana dizilmesinden ziyade bir antenin gereken konumlara taşınması ile oluşturulmaktadır. Taşınan anten bulunduğu her konumda radar sinyali gönderir ve geri yansıyan sinyali alarak kaydetmektedir. Kısacası SAR görüntülemeye kullanılan anten dizisi, tek bir antenin bir hava aracı ile taşınması ile oluşturulmaktadır. Bu antenlerin sinyalleri toplayabildiği alan, açıklık olarak adlandırılmaktadır. SAR görüntüleme süreci Şekil 2.1’de gösterilmiştir.

Belirli bir süre hava aracı sayesinde yapılan sinyal gönderim-alım döngüsü devam etmektedir ve kaydedilen veriler bir bilgisayarda işlenmektedir. Böylece bir antenin açıklık açısının kapasitesinden daha yüksek açısal çözünürlüğe sahip görüntü elde edilebilmektedir. SAR görüntüleme modlarından biri olan spot ışık modu kullanılarak antenin belirli bir alan üzerinde daha uzun süre durması ile çözünürlük daha da iyileştirilebilmektedir. Hedef üzerinde daha uzun olası bir sinyal gönderilme süresi yapay açıklığın artırılmasını doğrudan etkilemektedir.



Şekil 2.1. SAR görüntüleme sistemi.

2.2. ÇALIŞMA ALANI VE VERİ SETİ

Çalışmada kullanılan yüksek boyutlu SAR görüntüsü açık kaynak erişimli “Airbus Defence and Space” örnek radar görüntüleri veritabanından [30] alınmıştır. Tek polarize (VV kanalı) ve spot ışık modu kullanılarak elde edilen SAR görüntüsü 1m görüntü çözünürlüğüne sahiptir. Ayrıca elde edilen görüntü 16 bit ve 22000x19000 boyutlarındadır. Hindistan’da 17°44’05.6 "N enlemi ve 83°19’12.0 "E boylamında bulunan Visakhapatnam Limanı çalışma alanı olarak kullanılmıştır ve Şekil 2.2’de verilmiştir. Çalışma alanı bina, bitki örtüsü, kıyı, su ve yol içeren alanları kapsamaktadır.


Geniş alanları kapsayan SAR görüntüsü, kayan pencere yöntemi kullanılarak 100x100 yamaya bölünmüştür. Kayma miktarı, her yamanın farklı özelliklere sahip olacağı şekilde ayarlanmıştır. Yamalar, Google gerçek referans değerleri kullanılarak koordinatlarına göre otomatik olarak kategorize edilmiştir. Veri seti sırasıyla %70 -

%15 - %15 ayırımına karşılık gelen eğitim, doğrulama ve test setlerine bölünmüştür. Şekil 2.3'te her bir sınıfa ait görüntü örnekleri gösterilmektedir. Ayrıca, veri kümesi bölüldükten sonra her bir sınıfa ait görüntü sayısı artırılmıştır.



Şekil 2.2. Hindistan'daki Visakhapatnam Limanı.

Veri kümesi 2208 su, 2324 bina, 2344 bitki örtüsü, 1860 yol ve 2024 kıyı sınıfı görüntüsü içermektedir. Arazi kullanımı olarak adlandırılan yollara ait yama görüntüleri kavşakları, otoyolları ve demiryollarını içermektedir.



Şekil 2.3. Veri setini oluşturan sınıfların örnek olarak görselleştirilmesi.

Bir diğerk arazi kullanımı olarak tanımlanan bina sınıfında ise iş yerleri, evler ve fabrikalar gibi yapılar bulunmaktadır. Arazi örtüsü olarak belirtilen bitki örtüsü sınıfında ise ağaçlık, ormanlık ve çiftlik alanları gibi yeşil alanlar yer alıyor. Kıyı sınıfına ait olan yama görüntüleri ise su ve karanın bir arada bulunduğu su kıyısı olan alanları temsil etmektedir.

2.3. ÖN İŞLEMLER

SAR görüntülerinde ışık gibi doğal faktörlerin neden olduğu benek gürültülü görüntüleri oluşmaktadır. Sınıflandırma ağlarının daha iyi performans göstermesi için bu gürültülerin mümkün olduğunca azaltılması gerekmektedir. Bu çalışmada görüntüler sınıflandırma modellerine girdi olarak gönderilmeden önce benek gürültüsü azaltma filtresi kullanılarak ön işlemden geçirilmiştir. Kullanılan benek gürültüsü azaltma filtresi ve son zamanlarda kullanılan diğerk filtreler Bölüm 2.3.1’de detaylı bir şekilde anlatılmaktadır.

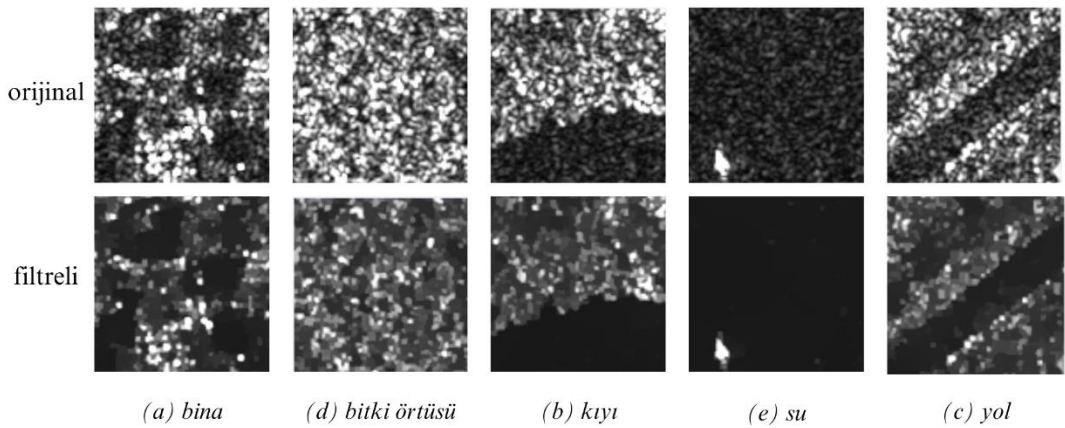
2.3.1. Benek Gürültüsü Azaltma

Benek gürültüsü, görüntü üzerinde rastgele farklılıklarının gözlemlendiği küçük parlak bölgelerdir. SAR verileri, görüntülerinin yorumlanmasını zorlaştırabilen beneklerin varlığından etkilenmektedir [32]. Bu durum görüntülerin ayırt edici özelliklerin belirlenmesini zorlaştırmakta ve sınıflandırma süreçlerini olumsuz yönde etkilemektedir. Özellikle, küçük nesnelere benek gürültüsü olan bölgelerle karıştırılabilmektedir. Bu soruna çözüm olarak bir çok benek gürültüsü giderme yöntemleri geliştirilmiştir.

Molini vd. [33], gürültünün korelasyon yapısını hesaba katmak amacıyla değışken miktarda pikseli hariç tutarak kısıtlandığı kör nokta evrişimli ağlarının özelleştirilmiş bir versiyonunu kullanmıştır. Bu çalışma tamamen gerçek tek görünümlü karmaşık SAR görüntülerine dayanan ilk derin öğrenme benek gürültüsü azaltma yöntemlerinden biri olmuştur. Bir diğerk CNN tabanlı yaklaşım olarak artık ağların dahil edildiği ve örnek alan görüntülerinin zaman ortalamalı kümülatif yumuşatmasını çarpımsal gürültüden arındırılmış bir görüntü olarak kullanıldığı yöntem olmuştur

[34]. Dalsasso vd. [35], yarı denetimli bir derin öğrenme algoritması önermiştir. Önerdikleri SAR2SAR algoritması çoklu-zamansal zaman serilerinden yararlanır ve sinir ağı sadece gürültülü edinimlere bakarak SAR görüntülerini geri yüklemeyi öğrenmiştir. Ancak derin öğrenme algoritmalarını eğitmek için benek gürültülü ve benek gürültüsüz SAR görüntüsü gerekmektedir [35]. SAR görüntüsünü beneksiz bir görüntüyle eşleştirmek üzere beneksiz referansların doğal bir kütüphanesi vardır. Bu tür görüntüler uzamsal veya zamansal entegrasyon yoluyla bir çeşit ortalama alma yoluyla dolaylı olarak elde edilebilse de kusurludur [36].

Çalışmada, görüntüler derin öğrenme ağına aktarılmadan önce, SDD [31] ile benek gürültüsü azaltma filtrelemesi uygulanmıştır. SDD filtresi, SAR görüntülerinde ışık gibi doğal faktörlerin neden olduğu gürültüyü ortadan kaldırmaktadır. Bu sayede SAR görüntülerinin kalitesi önemli ölçüde artmış ve derin öğrenme modelleri ile analiz süreci daha kolay hale gelmiştir. Şekil 2.4'te SDD filtresi uygulanmış görüntülere örnek verilmiştir. Görüldüğü üzere üst satırdaki orijinal görüntüler ile alt satırda bulunan filtrelenerek ön işlemden geçirilmiş görüntüler arasında oldukça fark bulunmaktadır. Örneğin bina sınıfına ait görüntünün orijinal hali bitki sınıfı ile neredeyse ayrıştırılamazken filtre uygulanmış halinde bina sınıfına ait olduğu açıkça anlaşılmaktadır.



Şekil 2.4. Orijinal görsel ve filtrelenmiş görsellerin örneklendirilmesi.

Farklı norm değerleri kullanılarak görüntüler üzerinde gerçekleştirilen benek giderme işlemini optimize eden SDD filtresinin matematiksel modeli Eşitlik 2.1'de gösterilmektedir [30].

$$F = \underset{F}{\operatorname{argmin}} \left[\sum_p (F_p - G_p)^2 + \lambda \Lambda(|(\partial F)_p|, f) \right] \quad (2.1)$$


Burada G benekli görüntüyü, F benek gürültüsü olmayan görüntüyü, p piksel indislerini ve λ yumuşatma seviyesini göstermektedir. Bu eşitlikte, norm değeri f değişkenine bağlıdır ve f değişkeni 0 değerini aldığımda l_0 -norm, 1 değerini aldığımda ise l_1 -norm olarak ifade edilmektedir. Böylece seyrek bir çözüm sağlanarak kesirli bir norm değeri elde edilmektedir.

2.3.2. Veri Artırma

Derin öğrenme modellerinin eğitilmesi için genellikle büyük miktarda veri gerektirmektedir. Ancak oluşturulan veriler, veri etiketlemenin zorluğu ve zaman gerektirmesi gibi çeşitli sebeplerden dolayı sınırlı olabilmektedir. Bu durumlarda veri artırma yöntemleri kullanılmaktadır. Veri artırımı, orijinal veriler üzerinde gerçekleştirilen belirli dönüşümler yoluyla ek ve daha çeşitli veri örnekleri üretmeyi amaçlamaktadır. Veri artırma, derin öğrenme ağlarının eğitim verisini çeşitlendirmek ve genişletmek için kullanılan bir tekniktir. Bu teknik, mevcut eğitim verisini çeşitli yöntemlerle dönüştürerek yeni örnekler oluşturmayı amaçlamaktadır. Bu, modelin daha genelleştirilebilir hale gelmesine, aşırı uyum göstermeyi azaltmasına ve daha iyi sonuçlar elde etmesine yardımcı olmaktadır. Ayrıca, veri artırma yöntemleri ile veri setinin genişletilebilmesi sayesinde daha az etiketli veri ile çalışılabilmektedir. Bu da etiketleme işlemi için gereken emek ve zamandan tasarruf sağlamaktadır. Görüntü verilerinde, yatay veya dikey döndürmeler, rastgele kırpma, parlaklık ayarlamaları, renk değişiklikleri gibi dönüşümlerle uygulanabilmektedir.

Veri artırma işlemleri uzaktan algılama görüntülerindeki arazi örtüsü ve kullanımı topolojilerini değiştirmez, bu da esasen tutarlı bir şekilde sınıflandırılması için önemlidir. Bu işlemler veri için spektral veya topolojik bilgiyi artırmaz. Öte yandan,

tek bir görüntü için çevirme, ötleme ve döndürme gibi veri artırımı yöntemleri topolojik korumaya tabi olarak bütünsel uzamsal düzenini ve yönünü çeşitlendirir [37]. Çalışmada, arazi örtüsü ve kullanımını sınıflandırmak için elde edilen görüntüler göz önünde bulundurulduğunda, veri artırımı tekniği, sınıf içi veri çeşitliliğini artırmakta ve sınıflar arası belirsizliklere neden olmamaktadır.



Şekil 2.5. Veri artırımı.

Çalışmada oluşturulan veri setine veri artırma yöntemlerinden döndürme işlemi uygulanmıştır. Şekil 2.5'te her sınıftan birer tane görüntünün döndürülmüş haline örnek verilmiştir. İlk sütunda görüntülerin orijinal hali (0° döndürme), devamında ise orijinal görüntünün 90, 180 ve 270 derece döndürülmüş halleri bulunmaktadır. Bu sayede veri seti miktarı dört katına çıkarılmıştır.

BÖLÜM 3

EVRIŞİMLİ SİNİR AĞLARI

CNN, görüntü işleme, görüntü tanıma ve birçok yapay zeka görevinde büyük başarı elde etmiş güçlü bir derin öğrenme modelidir. İnsan beyninin görüntü tanıma sisteminin işlevinden ilham alan bu ağlar, görüntülerden önemli özellikleri otomatik olarak çıkararak tanıma, sınıflandırma ve bölütleme gibi görevleri yerine getirmektedir. CNN, evrişim ve havuzlama katmanlarından oluşan özel bir mimariye sahiptir. Evrişimli katmanlar, görüntülerdeki belirli kalıpları tanımak için birbirine bağlı filtreler kullanırken, havuzlama katmanları özellik haritalarının boyutunu azaltarak öğrenme sürecini hızlandırır. Böylece CNN, büyük veri kümeleri üzerinde verimli bir şekilde öğrenerek yüksek doğruluk ve genelleme yeteneğine sahip olmaktadır. CNN, günümüzde, sürücüsüz araçlar, tıbbi görüntüleme, nesne tespiti gibi birçok alanda kullanılmaktadır.

3.1. ALEXNET


Derin öğrenme alanında büyük bir etki yaratmış bir sinir ağı olan AlexNet, görüntü sınıflandırma görevi için özel olarak tasarlanmış bir modeldir. 2012 yılında Alex Krizhevsky ve ekibi tarafından geliştirilen AlexNet [38], ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ImageNet Large Scale Visual Recognition Challenge, ILSVRC) büyük bir başarı elde etmiştir.

CNN modeline dayanan AlexNet, görüntülerin özelliklerini çıkarmak için evrişim ve havuzlama katmanlarından oluşan bir evrişim bloğu kullanır. Bu özelliği ile geleneksel yöntemlere kıyasla daha iyi performans sağlamaktadır AlexNet mimarisi derinlik açısından, 8 katmanlı bir sinir ağıdır. İlk beş katmanı, evrişim ve havuzlama katmanlarından oluşurken, altıncı, yedinci ve sekizinci katmanlar tam bağlantılı katmanlardan oluşmaktadır. Bu yapı, modelin karmaşık özellikleri başarılı bir şekilde

yakalayabilmesini sağlamak amacıyla kullanılmaktadır [38].

AlexNet, Doğrultulmuş Lineer Birim (Rectified Linear Unit, RELU) aktivasyon fonksiyonunu kullanır. ReLU, geleneksel aktivasyon fonksiyonlarına göre daha hızlı hesaplanabilir ve ağın eğitimini hızlandırır. Bu da modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlar. Ayrıca AlexNet, aşırı öğrenmeyi azaltmak için seyreltme tekniğini kullanır. Seyreltme, rastgele olarak seçilen sinir hücrelerinin belirli bir olasılıkla kapatılmasıdır. Bu sayede, ağı daha genelleştirilebilir bir şekilde öğrenme yapmasını sağlar ve aşırı öğrenme riskini azaltır. AlexNet modelinin katmanları Şekil 3.1’de gösterilmiştir.

Ek olarak, modelin büyük boyutlu veri kümesi üzerinde daha hızlı ve etkili bir şekilde eğitilmesi için eş zamanlı işlemler yapılmaktadır. Uygulanan paralel işleme, hesaplama süresini önemli ölçüde azaltarak modelin performansını artırmaktadır. AlexNet, ImageNet [39] veri kümesi üzerinde yüksek performans göstermiş ve sınıflandırma hatalarını önemli ölçüde azaltmıştır. Bu model, derin öğrenme ve görüntü işleme alanlarında bir dönüm noktası olmuştur. AlexNet, daha sonra geliştirilen birçok DNN modelinin temelini oluşturmuş ve halen benzer sınıflandırma görevlerinde yaygın bir şekilde kullanılmaktadır.



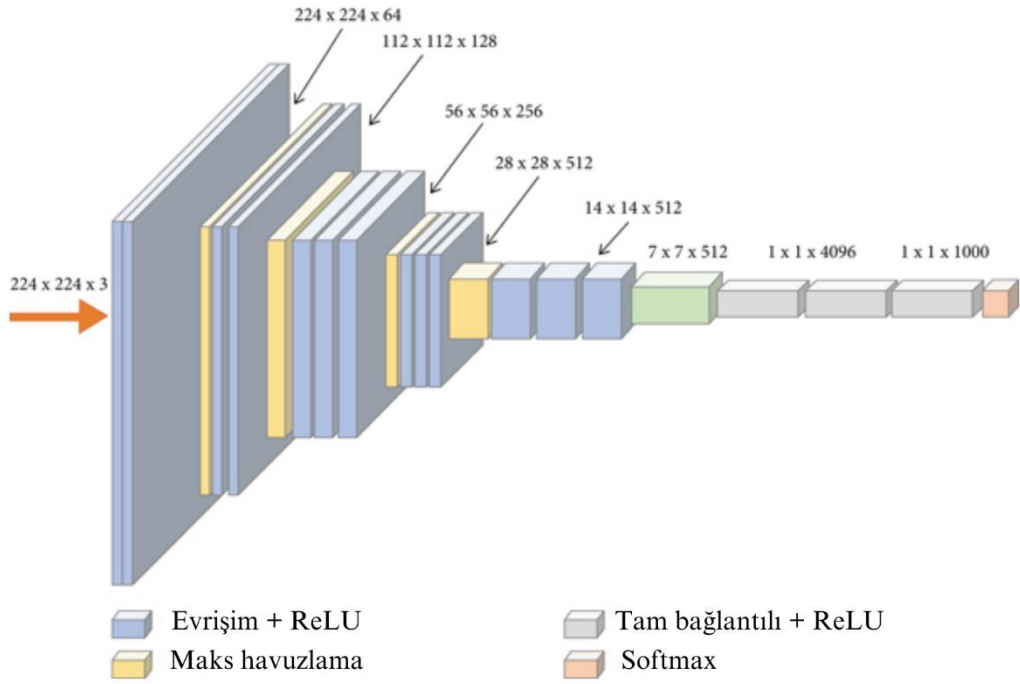
Şekil 3.1. AlexNet modeline ait katmanlarının yapısal gösterimi [38].

3.2. VGG-16

Görsel Geometri Grubu (Visual Geometry Group, VGG) tarafından geliştirilen ve ismini geliştircisinden alan VGG [40], derin CNN modelleri arasında önemli bir kilometre taşı olan mimaridir. CNN modellerine yaygın bir örnek olan VGG, ImageNet veri kümesi üzerindeki sınıflandırma görevlerinde büyük başarılar elde etmiştir. VGG modelinin kendinden önce geliştirilen diğer CNN modellerinden ayıran temel özelliği, son derece derin olması ve 3x3 boyutunda çok küçük filtrelerin kullanılmasıdır.

VGG, genellikle 224x224 piksel boyutundaki görüntüleri kullanır. Yapı olarak, ardışık bir şekilde birbirini takip eden birçok evrişim katmanı ve ardından tam bağlantılı katman içerir. Her evrişim katmanı, filtrelerin görüntü üzerinde kaydırılması ve evrişim işleminin uygulanmasıyla özellik haritaları oluşturur. VGG, 3x3 boyutunda küçük filtreler kullanarak, daha derin ve karmaşık özelliklerin çıkarılmasına odaklanır. Evrişim katmanlarının ardından, pozitif değerleri korurken negatif değerleri sıfır yaparak ağı daha hızlı ve etkili bir şekilde öğrenmesini sağlayan ReLU aktivasyon fonksiyonları uygulanır. Ardışık evrişim katmanları arasında havuzlama katmanları bulunur. Havuzlama katmanları, özellik haritalarının boyutunu azaltarak hesaplama yükünü ve parametre sayısını azaltırken ağı öğrenme sürecini hızlandırır. Havuzlama katmanlarından sonra, bir veya birden fazla tam bağlantılı katman gelir. Bu katmanlar, özellikleri sınıflandırma için kullanılır ve son tam bağlantılı katmandan sonra Softmax fonksiyonu kullanılarak, görüntünün farklı sınıflara ait olma olasılıkları hesaplanır. Özellikle son ağ katmanında kullanılan Softmax ile ağı çıktılarını $[0, 1]$ aralığına sıkıştırılarak ve bu çıktılarının toplamının 1'e eşit olması sağlanarak sınıf olasılıkları elde edilir. Böylece her bir sınıfa ait olasılıklar elde edilerek en yüksek olasılığa sahip sınıf belirlenmektedir. VGG modelinin katmanları Şekil 3.2'de gösterilmiştir.

VGG modeli, görüntü tanıma ve sınıflandırma alanlarında derin CNN'in kullanımının yaygınlaşmasına önemli bir katkı sağlamıştır. Küçük boyutlu filtreleri ve derin mimarisiyle, hem iyi performans hem de daha az parametre sayısı sunarak, derin öğrenme araştırmalarında önemli bir dönüm noktası olmuştur. Günümüzde hala birçok görüntü sınıflandırma ve nesne tanıma uygulamalarında kullanılmaktadır.



Şekil 3.2. VGG modeline ait katmanlarının yapısal gösterimi [40].

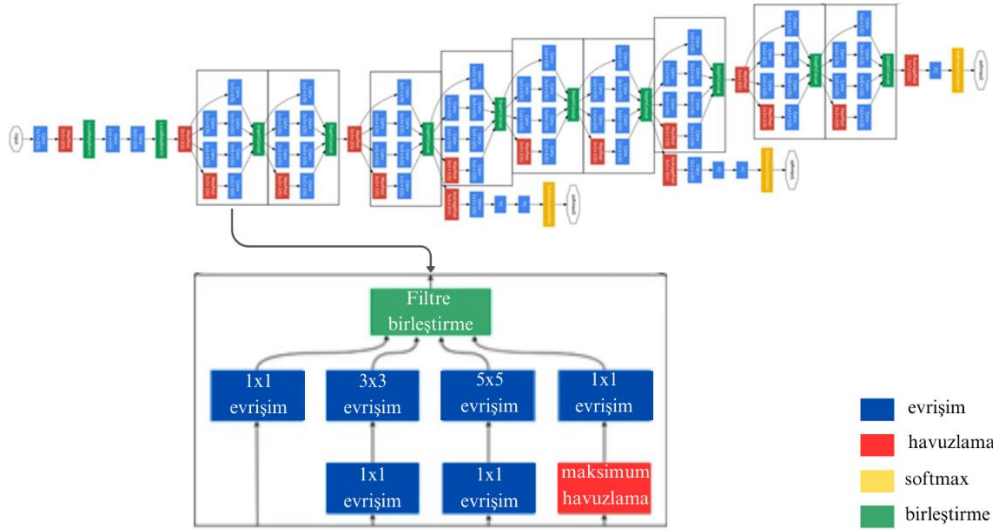
3.3. GOOGLNET

Derin öğrenme alanında AlexNet'ten sonra önemli bir ilerleme kaydeden GoogleNet [41], Google tarafından geliştirilen bir sinir ağı modelidir. GoogleNet, ImageNet veri kümesi üzerindeki ILSVRC yarışmasında büyük bir başarı elde etmiştir. Çok daha düşük hata oranlarına sahip olmasıyla öne çıkmış ve sınıflandırma görevlerinde etkileyici sonuçlar vermiştir. Başlangıç adı verilen yenilikçi bir yapıyı kullanarak farklı ölçeklerdeki evrişim işlemlerini paralel olarak gerçekleştirir ve sonuçları birleştirir. Bu, ağı hem derinleştirir hem de genişletirken hesaplama maliyetini azaltır.

GoogleNet, ekstra sınıflandırma katmanları olan göz atma ağları kullanır. Bu katmanlar, ağın orta seviye özelliklerini doğrudan kullanarak yanlış tahminleri azaltmayı hedefler. Ağın orta bölümündeki girdilere dayalı bir sınıflandırma yapmak ve eğitim sırasında hesaplanan kaybı ağın toplam kaybına geri eklemek için kullanılır. Aynı zamanda ağın daha hızlı ve daha güvenilir bir şekilde öğrenmesini sağlar. GoogleNet, maksimum havuzlama ve ortalama havuzlama gibi farklı kümelendirme işlemlerini kullanır. Bu işlemler, özellik haritalarını küçültmek ve önemli bilgileri

korumak için kullanılır. AlexNet mimarisi gibi ReLU aktivasyon fonksiyonunu kullanır. Ayrıca aşırı uyum göstermesini azaltmak için seyreltme tekniğini kullanırken ek olarak ağı daha kararlı bir şekilde öğrenmesini sağlamak için toplu normalleştirme [42] fonksiyonunu kullanır.

GoogleNet, yenilikçi bir DNN mimarisi olarak derin öğrenme alanında önemli bir ilerleme sağlamıştır ve daha sonraki birçok sinir ağı modelinin temelini oluşturmuştur. Başlangıç modülleri, göz atma ağırları ve farklı aktivasyon fonksiyonları gibi özellikleriyle, daha hızlı, derin ve etkili bir model oluşturmuştur. GoogleNet'in başarısı, derin öğrenme araştırmalarını ilerletmiş ve birçok uygulama alanında kullanılmasını sağlamıştır. Ayrıca sıralı bir yapıda birbirinin üzerine evrişim ve havuzlama katmanlarını istifleme yaklaşımından sapan ilk CNN mimarilerinden biridir [43]. GoogleNet modelinin katmanlarına ait detaylar Şekil 3.3'te gösterilmiştir.

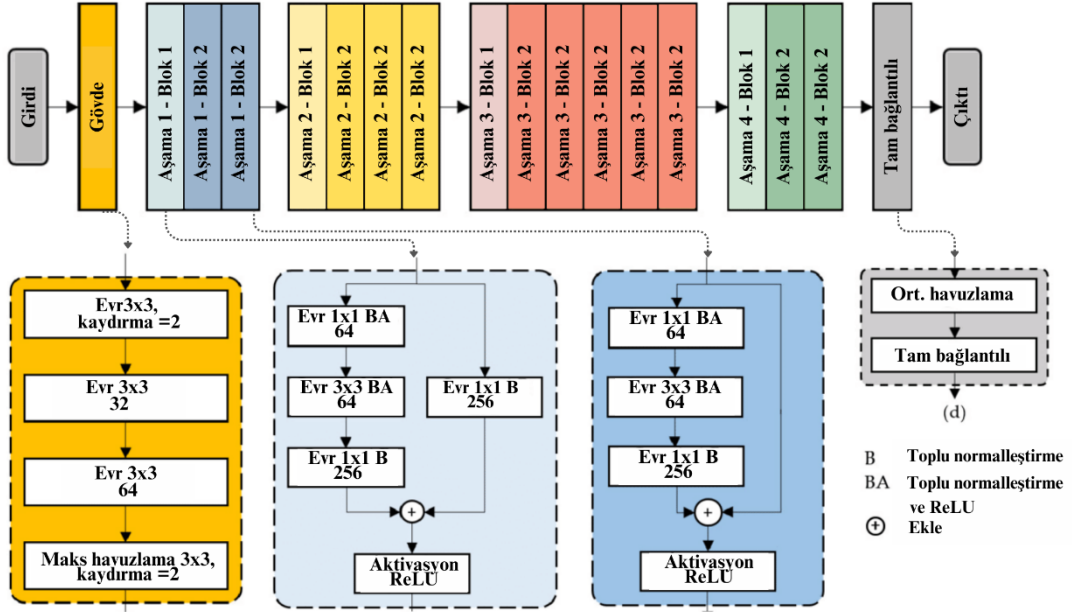


Şekil 3.3. GoogleNet modeline ait katmanlarının yapısal gösterimi [41].

3.4. RESNET

Derin öğrenme modellerinde ağ yapısının derinleşmesi sağlanarak önemli bir ilerleme kaydedilen ResNet [44] modeli, artık değerlerin sonraki katmanlara iletiildiği yenilikçi bir yapıya sahiptir. ResNet modelinde ağı derinliğini artırmak için artık bloklar

kullanılmaktadır. Atlama bağlantılarına sahip olan artık bloklar, eğitim sırasında kaybolan veya patlayan gradyan sorunları olmadan ağın derinleşmesini sağlamaktadır. Bu sayede daha karmaşık görüntülerde nesne tanıma problemlerinde daha iyi performans sunmaktadır.

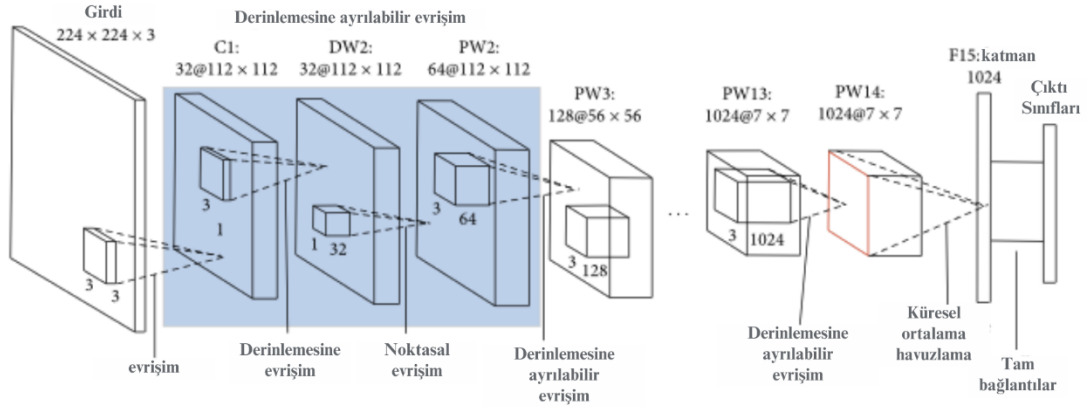


Şekil 3.4. ResNet modeline ait katmanlarının yapısal gösterimi [44].

ResNet modelinin yapısı VGG modeli temel alınarak oluşturulsa da VGG modeline kıyasla daha az filtre kullanılmaktadır ve karmaşıklık açısından daha düşüktür. Şekil 3.4'te gösterildiği gibi birçok bloktan oluşmaktadır ve her blok arasında artık bağlar bulunmaktadır. Bu bağlantılar, katmanların çıktılarını toplama işlemi uygulayarak, girdilerin doğrudan belirli katmanın çıktısına eklenmesini sağlamaktadır. Bu sayede, ağı öğrenme süreci kolaylaştırılmakta ve aşırı öğrenme riski azaltılmaktadır. ResNet modelinde 3x3 boyutunda evrişim filtrelerini yoğun olarak kullanılmaktadır. Bu sayede, daha az parametre ile daha etkili özellik çıkarımı yapılabilmektedir. Ağı sınıflandırma yapması için son katmanda tamamen bağlı katmanlar bulunur. Bu katmanlar, önceki katmanlardan gelen özellikleri alarak nihai sınıflandırma işlemini gerçekleştirmektedir.

3.5. MOBILENET

MobileNet [45], görüntü sınıflandırma, nesne algılama gibi görevlerde kullanılan, diğer ağlara göre daha küçük ve düşük gecikme süresine sahip bir modeldir. Boyutunun küçük olması sayesinde mobil cihazlarda derin öğrenme modeli olarak kullanılabilir. MobileNet'ler standart evrişimli katmanlar yerine derinlemesine ayrılabilir evrişimli katmanlar kullanmaktadır. Derinlemesine ayrılabilir evrişimler sayesinde daha az parametre bulunmaktadır. Modelin katmanlarının detaylı gösterimi Şekil 3.5'te verilmiştir. MobileNet mimarisinde bulunan derinlemesine ayrılabilir evrişimler ile geneleksel evrişimler arasındaki temel fark, tek 3x3 evrişim katmanı yerine 3x3 derinlemesine ayrılabilir evrişim ve 1x1 noktasal evrişim katmanı olarak ayrı ayrı kullanmasıdır. Bu yaklaşım ile önce evrişim katmanları ile özellik haritası hesaplanır ve 1x1 boyutundaki noktasal evrişim katmanı ile ölçeklendirilmektedir. Bu sayede, hesaplama maliyeti azaltılırken modelin temel özellikleri yakalama yeteneği korunmaktadır.




Şekil 3.5. MobileNet modeline ait katmanlarının yapısal gösterimi [45].

3.6. EFFICIENTNET

Derin öğrenme modellerinin karmaşıklığı artırıldıkça başarı oranı artmakta ancak işlem yükü de artmaktadır. Bu duruma çözüm olarak tasarlanan EfficientNet [46], derin öğrenme modellerinin karmaşıklığını artırırken hesaplama ve bellek maliyetini optimize etmektedir. EfficientNet, genişlik, derinlik ve çözünürlük olmak üzere üç

farklı boyutta ölçeklendirilebilen bir mimari sunmaktadır. Bileşik ölçeklendirme olarak adlandırılan bu yaklaşım ile her boyutun ölçeklendirilmesi dengeli bir şekilde sağlanmaktadır. Şekil 3.6’da gösterildiği gibi Mobil Ters Darboğaz Evrişim (Mobile-inverted Bottleneck Convolution, MBConv) adı verilen bloklar kullanılarak evrişim ve daraltma işlemleri gerçekleştirilmektedir. Böylece daha az kanala sahip katmanlar atlanarak daha etkili bir yol izlenmektedir. Ayrıca, EfficientNet, özellik haritasının boyutunu düşürmek ve hesaplama gücünü azaltmak için derinlemesine ayrılabilir ve noktasal evrişimleri bir araya getirmektedir. Derinlemesine ayrılabilir ve noktasal evrişimler, hesaplama maliyetini minimum doğruluk kaybıyla önemli ölçüde azaltmaktadır. Bu bağlamda, EfficientNet daha az parametre ile daha etkili modeller oluşturmanın yolunu açmıştır.

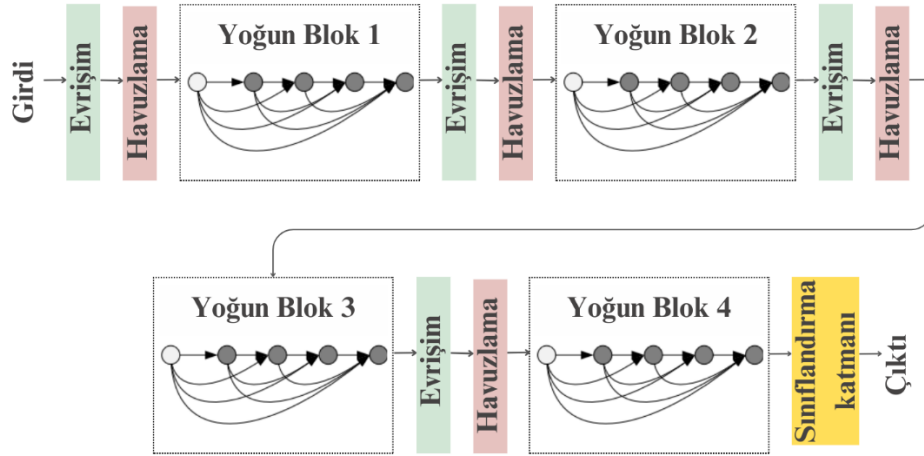


Şekil 3.6. EfficientNet modeline ait katmanlarının yapısal gösterimi [46].

3.7. DENSENET

Yoğun bağlantılar kullanan DenseNet [47], üstün düzeyde bilgi akışı sağlayan bir CNN modelidir. DenseNet, özelliklerin daha etkili paylaşılmasını amaçlayan bir yaklaşımı benimsemektedir. Geleneksel CNN modellerinde, her katman yalnızca bir önceki katmanın çıktısına bağlanırken, DenseNet’te her katman, önceki tüm katmanların çıktısına bağlanmaktadır. Her yoğun bağlantılı blok, bir dar boğaz katmanı ile başlar. Dar boğaz katmanı, özelliklerin boyutunu azaltan ve hesaplama

maliyetini düşüren bir 1x1 evrişim katmanıdır. Bu katman sayesinde ağ daha verimli hale getirilmektedir. Ayrıca DenseNet'in her katmanında, önceki katmanın çıktısına eklenen yeni özellik haritasının boyutunu kontrol eden bir büyüme oranı parametresi bulunur. Bu parametre, ağın karmaşıklığını ayarlamak için kullanılmaktadır. Yoğun bağlantılı bloklar arasında, geçiş katmanları yer almaktadır. Bu katmanlar, özellik haritalarının boyutunu azaltmak ve hesaplama maliyetini düşürmek için 1x1 evrişim ve 2x2 ortalama havuzlama işlemlerini içermektedir. DenseNet modelinin yapısal gösterimi Şekil 3.7'de verilmiştir. Ek olarak, modelde kullanılan genişlik ve derinlik çarpanı gibi parametreler bulunmaktadır. DenseNet bu parametrelerle ölçeklenebilmektedir ve bu parametreler modeli hafifletmek veya daha karmaşık hale getirmek için kullanılabilir.



Şekil 3.7. DenseNet modeline ait katmanlarının yapısal gösterimi [47].

DenseNet modelinin en önemli özelliklerinden biri özelliklerin tekrar kullanılabilmesidir. Yoğun bağlantılar sayesinde her katman, önceki katmanların özelliklerini kullanabilmektedir. Bu, daha önceki katmanlarda öğrenilen özelliklerin ağın daha derin katmanlarında da kullanılmasını sağlamaktadır. Böylece ağ daha iyi genelleme yeteneği kazanmaktadır. Bir diğer önemli özelliği ise aşırı uyum riskini azaltmasıdır. Her katmandan gelen gradyanlar, daha önceki katmanlara geri dönmesi sayesinde kaybolmamakla birlikte daha etkili bir şekilde kullanılmaktadır.

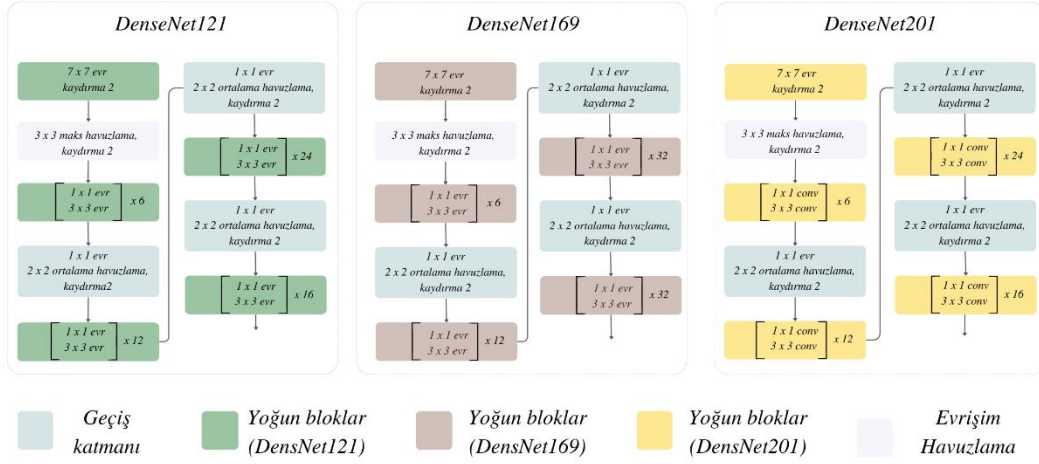
BÖLÜM 4

SARDE-NET TOPLULUK ÖĞRENME MODELİ

Topluluk öğrenme, farklı modelleri veya varyasyonları bir araya getirerek daha güçlü bir tahmin veya sınıflandırma modeli oluşturma yaklaşımıdır. Bu yaklaşımda, birden fazla CNN modeli eğitilir ve sonuçlar birleştirilirken oylama veya ortalama alma gibi yöntemler kullanılır. Her bir CNN modeli farklı ağırlık ayarları, hiper parametreler veya eğitim verisi alt kümeleri ile eğitilir. Sonuçta elde edilen tahminler, topluluk öğrenme yaklaşımına göre bir araya getirilir. Birden fazla modelin eğitilmesi modelin kararlılığını ve performansını azaltırken aşırı uyum gösterme riskini azaltmaktadır. Bu tez çalışmasında yoğun bloklara sahip olan DenseNet mimarileri ile topluluk öğrenme modeli geliştirilmiştir. Ayrıca topluluk öğrenme modellerinin dezavantajı olan hesaplama maliyeti sorununa çözüm olarak iyileştirmeler yapılmıştır. Bu bölümde geliştirilen SARDE-Net modeli anlatılmaktadır.

SAR görüntülerinde olduğu gibi nesnelerin ayırt edilmesinin zor olduğu görüntülerde yüksek performans elde etmek için SARDE-Net mimarisini öneriyoruz. Önerilen mimaride, bir dizi yoğun bloktan oluşan ve her blok arasında bir konvolüsyon işlemi içeren DenseNet mimarisinin yoğun bağlantıları ile yüksek performanslı bir topluluk modeli oluşturulmuştur. Derin öğrenme modellerinde katman ve işlem sayısı arttıkça katmanlardaki bilgi kaybının önüne geçilebilmektedir [5]. DenseNet mimarisi, her katmandaki özellik haritalarını ileri beslemeli ve yinelemeli bir şekilde birleştirerek diğer mimarilere göre daha yüksek bir bilgi akışı sağlar [19,48]. Güçlü özellik yayılımına sahip bu mimari, kaybolan gradyan problemini çözerken parametre sayısını azaltmaktadır.

Makine öğrenmesinde sıklıkla kullanılan topluluk yöntemi, bir problemi çözmek için birden fazla model veya model çıktısı kullanarak genelleme yapan bir tekniktir. Model oluşturulurken DenseNet-121, DenseNet-169 ve DenseNet-201 sınıflandırıcıları bir araya getirilmiştir. Derin öğrenme modellerinin eğitimi esnasında, her iterasyonda ağırlıklar optimize edilmektedir. Bu nedenle, modellerin eğitimi çok fazla zaman gerektirmektedir. Bu durumda ince ayar yapılarak önceden eğitilmiş bir modelin daha iyi doğruluk sağladığı görülmektedir [49]. İnce ayar, transfer öğrenmeyi uygulamanın veya kullanmanın bir yoludur. ImageNet veriseti üzerinde önceden eğitilmiş olan DenseNet mimarileri transfer öğrenme yaklaşımı ile kullanılmak üzere yapılandırılmıştır.



Şekil 4.1. Birleştirilen modellerin yapısal gösterimi.

Yapılandırılan modeller Şekil 4.1'de gösterilmiştir. Önceden eğitilmiş bu modeller kullanılarak katmanlar arasında yineleme ve bilgi aktarımı sağlanmıştır. Ayrıca birleştirilen modellerin her birinin ardından havuzlama katmanı eklenmiştir. Bu sayede özellik haritalarının boyutunu azaltarak hesaplama yükünü azaltılırken, belirgin özellikleri koruyarak önemli bilgilerin korunması sağlanmıştır. Eklenen havuzlama katmanının seçimi için her bir kombinasyon denenmiş ve en yüksek performansın elde edildiği kombinasyon kullanılmıştır. Bu kombinasyon DenseNet-121 ve DenseNet-169 modelinin küresel ortalama havuzlama, DenseNet-201 modelinin küresel maksimum havuzlama katmanına iletilmesi ile elde edilmiştir. Bu

aşamada, hiper parametrelerin ayarlanması için çeşitli kombinasyonlar denenmiş ve en yüksek performansı sağlayan parametreler Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. SARDE-Net mimarisinin bileşenleri olarak kullanılan ağlara ait parametreler.

	DenseNet-121	DenseNet-169	DenseNet-201
Çekirdek Boyutu	3x3	3x3	3x3
Aktivasyon Fonksiyonu	ReLU	ReLU	ReLU
Yoğun Katman	121	169	201
Havuzlama Katmanı	GlobalAverage	GlobalAverage	GlobalMax
Optimize Edici	Adam	Adam	Adam
Batch Boyutu	32	32	32

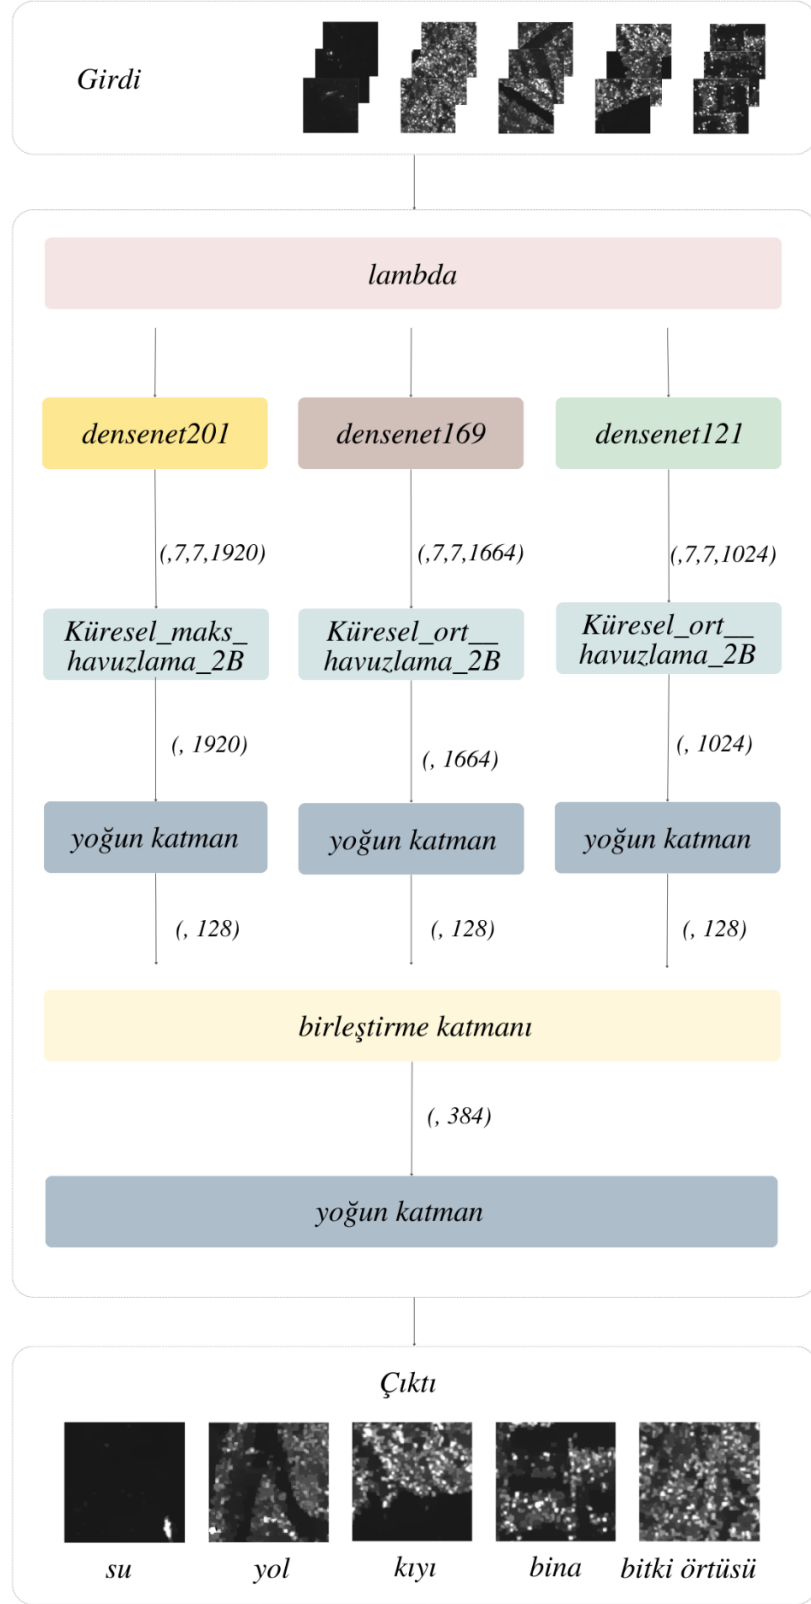
Ek olarak, topluluk öğrenme yönteminin hesaplama karmaşıklığını azaltmak için her bir modele ince ayar işlemi gerçekleştirilmiştir. İnce ayar işlemi için modellerin bazı katmanları dondurulmuştur. Katmanların dondurulması eğitimin esnasında önceden eğitilmiş modelin belirlenen ağırlıklarının korunması, yani güncellenmemesi anlamına gelmektedir. Sırasıyla her sınıflandırıcının sadece son katmanlarında ve eklenen katmanlarda ağırlık güncellemesi yapılmıştır. SARDE-Net mimarisine ait parametreler Çizelge 4.2’de verilmiştir.

Çizelge 4.2. SARDE-Net mimarisine ait parametreler.

Çekirdek Boyutu	3x3
Aktivasyon Fonksiyonu	Softmax
Yoğun Katman	495
Optimize Edici	Adam
Batch Boyutu	32
Toplam Parametre	38.594.501
Eğitilebilir Parametre	592.133

DenseNet modellerinin birleşmesi sonucu toplamda 38.594.501 adet parametre bulunmaktadır. Katmanların dondurulması ile bu sayı 592.133’e kadar düşürülmüştür. Bu sayede tüm katmanlardaki ağırlıkların güncellenmesi engellenerek önemli ölçüde

eđitilen parametre sayısı ve eđitim süresi azaltılmıřtır. Topluluk modelinde, girdiler Őekil 4.2’de gösterildiđi gibi bir lambda katmanına aktarılmaktadır. Lambda katmanı aracılıđıyla, tařınabilir olmayan ve sıralı iřlevler katman haline getirilmektedir. Girdi özelliklerinin boyutu bu katmana aktarılmaktadır. Lambda katmanına ait çıktı özellikleri DenseNet-121, DenseNet-169 ve DenseNet-201 mimarilerine ayrı ayrı girdi olarak iletilmektedir. Aktarılan çıktıları uygun bir havuzlama katmanından ve ardından yoğun katmandan geçirilmektedir. Ardından yoğun katmanların matrisleri birleřtirme katmanı aracılıđıyla birleřtirilmektedir. Bu katman aynı boyutta bir özellik matrisi alıp matrislerin birleřtirilmiř halini döndürmektedir. Böylece, bilgi kaybı olmadan topluluk modelinden çıktıları elde edilmektedir. Son olarak, birleřtirme katmanından geçen özellik matrisinin boyutu, yoğun katman ile çıktı sınıflarının boyutlarıyla eřleřtirilmektedir.



Şekil 4.2. SARDE-Net model mimarisi.

BÖLÜM 5

SAR GÖRÜNTÜLERİNDE ARAZİ ÖRTÜSÜ VE KULLANIMININ SINIFLANDIRILMASI

Bu bölümde önerilen yöntemin performansını ölçmek için deneysel çalışmalar gerçekleştirilmiştir. Kullanılan yöntemler, bir Jupyter defteri üzerinde çalışmak üzere Python dilinde geliştirilmiştir. Donanım gücü olarak Google Colaboratory ortamının sunduğu NVIDIA Tesla T4 GPU kullanılmıştır. Deneysel çalışmalarda modellerin eğitimi Keras ve TensorFlow çerçevesi kullanılarak gerçekleştirilmiştir.

Derin öğrenme çalışmalarında, model eğitiminin hesaplama maliyetinin yüksek olması yaygın bir sorundur [22]. Bu sorunun üstesinden gelmek için transfer öğrenme yaklaşımı kullanılmaktadır [25]. Transfer öğrenme yaklaşımında, büyük ve heterojen veri seti üzerinde önceden eğitilmiş ağlar başka bir sınıflandırma görevinde kullanılmaktadır. ImageNet gibi çeşitli nesnelere binlerce görüntü içeren veri seti ile eğitim yapılmış bir ağın daha sonra bu eğitimden elde edilen ağırlıklar kullanılarak farklı bir veri seti ile sınıflandırma gerçekleştirilmesi transfer öğrenme yaklaşımına yaygın bir örnektir. Bu tez çalışmasında hesaplama maliyetinin minimum seviyede tutulması için transfer öğrenme yaklaşımından faydalanılmıştır. Ayrıca transfer öğrenme yaklaşımının bir yolu olan ince ayar çalışmada uygulanmıştır. İnce ayar işlemi için modellerin bazı katmanları dondurulmuştur. Katmanların dondurulması ile eğitim esnasında önceden eğitilmiş modelin belirlenen ağırlıklarının korunması, yani güncellenmemesi sağlanmıştır. Bu sayede dondurulan katmanlar ağırlıkların güncellenmesi için ekstra hesaplama gücü harcamamaktadır.

Derin öğrenme mimarilerinin her veri kümesi için eğitilmesi gereken iterasyon sayısı değişkenlik göstermektedir. Ağın ne kadar eğitileceğine en doğru şekilde karar verebilmek için ağın eğitim esnasında kayıp ve doğruluk değerleri incelenmesi gerekmektedir. Kayıp değerinin mümkün olan en düşük değere düşmesi ve aynı

zamanda doğruluk değerinin ise ulaşabileceği en yüksek değere ulaşması eğitimin başarısını ölçebilmektedir. Bu noktada ağı aşırı uyum sağlamasını önlemek için eğitimin durdurulması gerekmektedir. Bunun için çalışmada geri çağırma işlevi kullanarak erken durdurma yöntemi kullanılmıştır. Geri çağırma işlevi, her eğitim iterasyonunda metrikleri izlemek ve modeli periyodik olarak kaydetmek için kullanılmıştır. Her eğitim iterasyonundan sonra, model hakkında istatistiksel veriler sağlayan geri çağırma işlevi kullanılarak kayıt halinde tutulmaktadır. Erken durdurma fonksiyonu, modelin izlenen metriğinde herhangi bir gelişme olmadığında eğitimi durdurmaktadır.

Bu bölümde, tez çalışması kapsamında kullanılan verinin çapraz doğrulama uygulaması, uygulanan benek gürültüsü azaltma filtresinin model performansına etkisi ve geliştirilen topluluk öğrenme modelinin CNN modelleri ile karşılaştırılması ayrı başlıklar halinde ele alınmıştır.

5.1. PERFORMANS ÖLÇÜM METRİKLERİ

Derin öğrenme modelinin başarısı, doğru pozitif (DP), doğru negatif (DN) yanlış pozitif (YP) ve yanlış negatif (YN) tahmin sayıları kullanılarak hesaplanmaktadır. Bu değerler karmaşıklık matrisinden elde edilmektedir. Çizelge 5.1’de, tahmin edilen ve gerçek değerleri gösteren karmaşıklık matrisine yer verilmiştir.

Çizelge 5.1. Karmaşıklık matrisi.

	Gerçek Pozitif	Gerçek Negatif
Tahmin Edilen Pozitif	DP	YP
Tahmin Edilen Negatif	YN	DN

DP değeri, gerçek etiketinin model tahminlerinde de aynı şekilde görüntülenmesidir. YN değeri, gerçek etiketin diğer sınıfa ait olduğunu göstermektedir. YP değeri, gerçek etiketin diğer sınıfa ait olduğu durumdur. DN değeri, gerçek etiket ile tahmin edilen nesnenin aynı olduğu doğru tahminidir. Burada negatif olması, ikili sınıflandırmalarda bir sınıfa 1, diğer sınıfa 0 etiketinin atanarak değerlendirilmesinden

kaynaklanmaktadır. Bu çalışmada çok sınıflı bir sınıflandırma problemi üzerinde durulmaktadır. Arazi örtüsü ve arazi kullanımı sınıfları beşe ayrılmaktadır. Çizelge 5.2 ile birlikte bu probleme göre DP, DN, YP ve YN değerleri açıklanmaktadır.

Çizelge 5.2. Çok sınıflı sınıflandırma karmaşıklık matrisi.

	Bina	Bitki örtüsü	Kıyı	Su	Yol
Bina	a	b	c	d	e
Bitki örtüsü	x				
Kıyı	y				
Su	z				
Yol	j				

Bina sınıfı için ele alındığında DP sayısı a kadardır. YN sayısı, gerçek etiketlerin tutulduğu ilgili satırda DP hariç diğer sayıların toplamına ($b + c + d + e$) eşittir. YP ise tahmin edilen etiketlerin tutulduğu ilgili sütunda DP hariç diğer değerlerin toplamına ($x + y + z + j$) eşittir. DN ise ele alınan sınıf ile kesişimi olmayan (çizelgedeki boş alanlar) tüm değerlerin toplamına eşittir.

DP, DN, YP ve YN değerleri, derin öğrenme modellerinin performans ölçümünde kullanılan doğruluk, kesinlik, duyarlılık ve f1-skoru metriklerinin hesaplanmasında kullanılmaktadır. Eşitlik 5.1’de verilen doğruluk metriği, modelin tüm tahminler arasından ne kadarının doğru yapıldığını ölçmek için kullanılmaktadır.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (5.1)$$

Kesinlik metriği, pozitif olarak tahmin edilen sınıfların gerçekte hangi oranda doğru tahmin edildiğini hesaplamaktadır. Matematiksel olarak Eşitlik 5.2’de gösterilmiştir.

$$Kesinlik = \frac{DP}{DP+YP} \quad (5.2)$$

Eşitlik 5.3’te verilen duyarlılık metriği, oluşturulan modelin gerçek pozitiflerin ne kadarını doğru bir şekilde bulduğunu ölçmek için kullanılmaktadır.

$$Duyarlılık = \frac{DP}{DP+YN} \quad (5.3)$$

F1-skoru metriği, kesinlik ve duyarlılık metriklerinin harmonik ortalamasını vermektedir. Bu iki metriğin ne kadar iyi dengelendiğini belirlemek için kullanılmaktadır. Daha yüksek bir f1-skoru hem kesinliğin hem de duyarlılığın yüksek olduğunu göstermektedir. F1-skorunun hesaplanması Eşitlik 5.4'te gösterilmiştir.

$$F1-skoru = 2 \times \frac{Duyarlılık \times Hassasiyet}{Duyarlılık + Hassasiyet} \quad (5.4)$$

5.2. K-KAT ÇAPRAZ-DOĞRULAMA

Veri setini verimli bir şekilde oluşturmamızı sağlayan yama tabanlı yaklaşım, çalışmanın yüksek performans göstermesinin nedenlerinden biridir. Bu bağlamda, veri kümesinin dağılımını ve modelin güvenilirliğini incelemek için çapraz doğrulama yöntemi kullanılmıştır. Çapraz doğrulama, modelin farklı veri alt kümeleri üzerindeki performansını gözlemleyerek genelleme yeteneğini analiz etmeyi sağlamaktadır. Çizelge 5.3, 5-kat ile elde edilen sonuçları göstermektedir.

Çizelge 5.3. 5-kat çapraz doğrulama sonucu.

Kat	Doğruluk (%)	Kesinlik (%)	F1-skoru (%)
1	92,62	92,74	92,53
2	90,92	91,39	90,78
3	91,87	92,03	91,82
4	93,44	93,71	93,40
5	91,94	92,09	91,74
ORT	92,16	92,39	92,05

Bu sonuçların analizi, doğruluk değerleri arasında aykırı bir fark olmadığını göstermektedir. Dolayısıyla modelin ve veri seti dağılımının güvenilirliği açıkça ortaya koyulmaktadır.

5.3. SARDENET

Çalışmada kullanılan SAR görüntüsü 8 bit olarak elde edilmiştir ve 22000x19000 boyutundadır. Geniş alanları kapsayan SAR görüntüleri, derin öğrenmenin verimli kullanımı için gereksiz özelliklerden kaçınmak ve ağır sınıflara odaklanmasına izin vermek için 100x100 yamaya bölünmüştür. Yamalar, Google temel gerçekleri kullanılarak koordinatlarına göre otomatik olarak sınıflara ayrılmıştır. Benek gürültüsü filtrelemesi, yamalara bölünmüş SAR görüntülerine bir SDD filtresi uygulanarak gerçekleştirilmiştir. Yama tabanlı yaklaşımda görüntülerin benzerliğini önlemek için farklı piksel kaydırma oranları uygulanmıştır.

Transfer öğrenme kullanılarak bir araya getirilecek modeller SAR görüntüleri üzerinde sınıflandırma görevi için yapılandırılmıştır. Yapılandırma, her bir iterasyonda tüm parametrelerin eğitilmesinin zaman alması ve önceden eğitilmiş ağır parametrelerinin eğitildiği veri kümesine özgü olması nedeniyle yapılmıştır. Kullanılan modellerin belirli katmanları eğitilemez hale getirilerek ağırlıkların güncellenmesi engellenmiştir. Bu işlem, modeldeki parametre sayısını azaltarak daha hızlı eğitim sağlamaktadır. İnce ayar olarak bilinen bu süreçte, önceden eğitilmiş özellikler kademeli olarak verilere uyarlanmakta ve anlamlı iyileştirmeler sağlanmaktadır. Bu sayede katmanlar daha alakalı hale getirilmektedir.

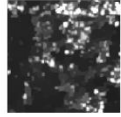
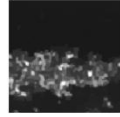
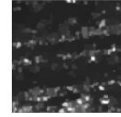
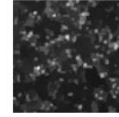
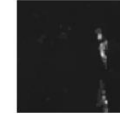
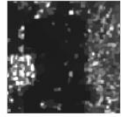
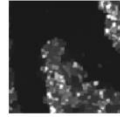
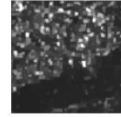
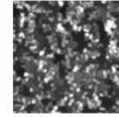

Çizelge 5.4. SARDE-Net mimarisinin sınıf bazlı sınıflandırma sonuçları.

	Kesinlik (%)	Duyarlılık (%)	F1-skoru (%)
Bina	96,95	99,43	98,18
Bitki örtüsü	99,43	99,72	99,57
Kıyı	99,66	98,02	98,83
Su	99,10	100	99,55
Yol	98,89	96,07	97,46
Ortalama	98,78	98,77	98,76

SARDE-Net mimarisine ait performans değerleri Çizelge 5.4'te verilmiştir. Performans ölçümü için doğruluk, kesinlik, duyarlılık ve f1-skoru metrikleri

kullanılmıştır. Sırasıyla % 98,77 doğruluk, %98,78 kesinlik, %98,77 duyarlılık ve %98,76 f1-skoru değerlerine ulaşılmıştır.

Şekil 5.1’de SARDE-Net modelinin eğitilmesi ardından yapılan sınıflandırma tahminlerine örnek verilmiştir. Burada, DP doğru yapılan tahminleri, YP ise yanlış yapılan tahminleri temsil etmektedir. Yanlış sınıflandırılan görüntülerin gerçek sınıfı (etiketi) alt satırda verilmiştir. Model için kafa karıştırıcı unsurlar buradan anlaşılacaktır. Örneğin, yol sınıfındaki bir görüntü, yol kenarındaki karanlık bölgeler nedeniyle bina sınıfı ile karıştırılmaktadır. Kıyı sınıfındaki bir görüntü, muhtemelen limandaki bir gemi veya nesneden geri saçılan sinyallerin etkisiyle parlak noktalara sahiptir ve su sınıfına atanmıştır. Bu gibi etmenlere rağmen geliştirilen model yüksek başarıya ulaşmıştır.

	<i>bina</i>	<i>kıyı</i>	<i>yol</i>	<i>bitki örtüsü</i>	<i>su</i>
DP					
YP					
etiket	<i>yol</i>	<i>su</i>	<i>kıyı</i>	<i>bina</i>	<i>kıyı</i>

Şekil 5.1. SARDE-Net modelinin sınıflandırma çıktılarının örneklendirilmesi.

5.4. SDD FİLTRESİNİN PERFORMANSA ETKİSİ

SAR görüntülerinin benek azaltma veya benek giderme amaçlı bir ön işleme tabi tutulması birçok uygulama için büyük önem taşımaktadır [50]. Daha önce yapılan çalışmalar görüntüler üzerinde iyileştirme yapıldığında sınıflandırma performansını önemli ölçüde iyileştirdiğini göstermektedir. Bu çalışmada yerel olmayan ortalama filtrenin doku koruma özelliğinden yararlanan SDD filtresi kullanılmaktadır. Bu yöntemin kullanılmasının en büyük sebeplerinden biri kenar ve noktasal saçıcıların bozulmasını önleyerek homojen bölgelerin başarılı bir şekilde yumuşatılmasını sağlamasıdır. Ayrıca ön işlem olarak kullanılan bu görüntü filtreleme adımının zaman ve doğruluk açısından yüksek performans göstermesine dikkat edilmiştir.

Görüntülerin SDD filtresinden geçirilerek ön işleme yapılmasının çalışmaya katkısını incelemek için SAR görüntüleri filtrelenmeden, orijinal hali ile sınıflandırma gerçekleştirildi. Çizelge 5.5'te orijinal ve SDD filtresi ile ön işlemde geçirilen SAR görüntülerinin SARDE-Net ile sınıflandırılarak elde edilen performans sonuçları, her bir sınıf için verilmiştir. Bu sonuçları karşılaştırmak üzere tablo incelendiğinde her bir sınıf için kesinlik, duyarlılık ve f1-skoru metriklerinde kayda değer bir fark olduğu görülmektedir. Örneğin kıyı sınıfı için orijinal görüntü ile eğitim yapıldığında kesinlik değeri %96,43 iken SDD filtresi uygulanıp eğitim yapıldığında bu değer %99,66'ya ulaşmıştır. Genel doğruluk değerleri ise, orijinal görüntüler ile eğitim yapıldığında %97,14, filtreli görüntüler ile eğitim yapıldığında %98,77 olarak hesaplanmıştır. Yapılan deneysel çalışma SDD filtresinin sınıflandırma performansını oldukça artırdığını açıkça ortaya koymaktadır.

Çizelge 5.5. Orijinal ve filtreli görüntülerin sınıf bazlı sınıflandırma sonuçları.

Sınıf	Kesinlik (%)		Duyarlılık (%)		F1-skoru (%)	
	Orijinal	Filtreli	Orijinal	Filtreli	Orijinal	Filtreli
Bina	95,04	96,95	97,02	99,43	96,02	98,18
Bitki örtüsü	98,04	99,43	99,72	99,72	98,87	99,57
Kıyı	96,43	99,66	96,74	98,02	96,59	98,83
Su	99,09	99,1	99,39	100	99,25	99,55
Yol	96,98	98,89	91,78	96,07	94,31	97,46
Ortalama	97,14	98,78	97,14	98,77	97,12	98,76

5.5. CNN MODELLERİ İLE KARŞILAŞTIRMA

Görüntü sınıflandırma problemlerinde sıklıkla kullanılan ağlardan AlexNet, VGG-16, EfficientNet, GoogleNet, ResNet, MobileNet ve DenseNet modelleri çalışma kapsamında karşılaştırma yapmak için kullanılmıştır. Bu ağlar ile önerilen SARDE-Net aynı veri seti üzerinde eğitilmiş ve performansları Çizelge 5.6'da karşılaştırılmıştır. SARDE-Net mimarisinde kullanılan DenseNet-121, DenseNet-169 ve DenseNet-201 mimarilerinin bireysel performansları da karşılaştırma tablosunda yer almaktadır. Performans ölçümü için doğruluk, kesinlik, duyarlılık ve f1-skoru metrikleri kullanılmıştır. Elde edilen performans metriklerine bakıldığında doğruluk değerleri CNN modellerinde %93,62 ile %97,18 aralığındadır. DenseNet modellerinde ise %96,18 ile %97,18 aralığında olup diğer ağlardan daha iyi performans göstermiştir. Bu bağlamda yoğun bağlantıların ve transfer öğrenmenin avantajları birleştirilerek oluşturulan topluluk öğrenme modeli daha iyi bir performans göstermiş ve %98,77 doğruluk değerine ulaşmıştır. Deneysel sonuçlar, birleştirilen üç modelin diğer sınıflandırma modellerinden daha iyi performans gösterdiğini ve önerilen SARDE-Net'in en iyi performansı sağladığını sunmaktadır.

Çizelge 5.6. Sınıflandırma modellerinin performans değerleri.

Model	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skoru (%)
AlexNet	95,44	95,60	95,19	95,39
VGG-16	95,12	95,13	95,12	95,05
EfficientNet	96,42	96,42	96,09	96,22
GoogleNet	95,59	95,52	95,45	95,49
ResNet-50	95,44	95,28	95,28	95,28
ResNet-101	94,12	94,39	93,41	93,90
ResNet-152	93,78	94,19	93,13	93,65
MobileNet	93,62	93,49	93,53	93,51
DenseNet-121	97,09	97,09	96,88	96,98
DenseNet-169	96,18	96,21	95,92	96,07
DenseNet-201	97,18	97,37	96,81	97,09
SARDE-Net	98,77	98,78	98,77	98,76

BÖLÜM 6

SONUÇLAR VE ÖNERİLER

Tez kapsamında, derin öğrenmeye dayalı sınıflandırma yöntemlerinin arazi örtüsü ve kullanımı sınıflandırması için SAR görüntülerine uygulanması incelenmiştir. Sınıflandırma yaklaşımları, günümüzde uzaktan algılama verilerinin kıymetlendirilmesinde kullanılan yaklaşımlardan biridir. SAR görüntülerinin kalitesinin ve sayısının giderek artması sebebiyle, görüntülerin anlamlandırılması giderek önem kazanmaktadır. Ancak çok sayıda etiketli SAR görüntülerinin elde edilmesi ve yorumlanması uzaktan algılama için zorlu bir görevdir. Bu nedenle, bu çalışmada sınıflandırma yöntemlerinin SAR görüntülerine uygulanması ve performanslarının karşılaştırılması üzerine çalışılmıştır. Bu sayede SAR görüntülerinde sınıflandırma işlemi yapılarak görüntüdeki farklı arazi bölgeleri ve kullanımı sınıfları belirlenmeye çalışılmıştır.

Bu çalışmada, farklı bölgesel özellikleri içeren SAR görüntülerini sınıflandırmak için derin öğrenme tabanlı bir topluluk modeli önerilmiştir. Önerilen model, temel mimari olarak DenseNet modellerini birleştirmektedir. Birleştirme gerçekleştirilirken, parametre ve hesaplama karmaşıklığı azaltılmaktadır. Bu sayede modelin daha iyi performans göstermesi sağlanmıştır. Ek olarak, literatürdeki çalışmalar SAR görüntülerinde saçılmadan kaynaklanan benek gürültüsünün sınıflandırıcı performansını olumsuz etkilediğini göstermiştir. Bu çalışmada, benek gürültüsünü gidermek için bir SDD filtresi uygulanmış ve geliştirilen topluluk öğrenme modeli üzerinde filtrenin sınıflandırma performansına etkisi araştırılmıştır. Benek gürültüsünün azaltılmasından sonra her bir sınıf için kesinlik değerinde %3'e kadar artış meydana gelmiştir. Önerilen model %98,77 doğruluk, %98,81 kesinlik, %98,64 duyarlılık ve %98,72 f1-skoru değerlerine ulaşarak SAR görüntüleri üzerinde literatürde sunulan diğer son teknoloji derin öğrenme yöntemlerinden daha iyi performans göstermiştir. SAR görüntülerinin sınıflandırmasında yoğun katmanlar,

transfer öğrenme, görüntü işleme yöntemlerinin avantajları birleştirilen bu çalışma sonucunda;

- SAR görüntüsünde yama tabanlı bir yaklaşım izlenerek elde edilen görüntüler ile modelin sınıflandırma performansı iyileştirilmiştir.
- Ön işleme adımı olarak görüntülere uygulanan benek gürültüsü giderme işlemi sınıflandırıcının başarı oranını artırmıştır.
- Önerilen modelin, sınıflandırma kabiliyeti sayesinde SAR görüntüleri gibi karmaşık görüntü içeren büyük veri kümelerinde başarı gösterdiği teyit edilmiştir.

Bu alanda ileride yapılabilecek çalışmalar arasında, SAR görüntülerinin sınıf sayısının artırılması ve arazi örtüsü ve kullanımı için bölütleme çalışması yapılması mümkün olabilir.

KAYNAKLAR

1. Al-Najjar, H. A. H., Kalantar, B., Pradhan, B., Saeidi, V., Halin, A. A., Ueda, N., and Mansor, S., "Land cover classification from fused DSM and UAV images using convolutional neural networks", *Remote Sensing*, 11 (12): (2019).
2. Wu, Z., Hou, B., and Jiao, L., "Multiscale CNN with Autoencoder Regularization Joint Contextual Attention Network for SAR Image Classification", *IEEE Transactions On Geoscience And Remote Sensing*, 59 (2): (2021).
3. Chen, L., Weng, T., Xing, J., Pan, Z., Yuan, Z., Xing, X., and Zhang, P., "A new deep learning network for automatic bridge detection from SAR images based on balanced and attention mechanism", *Remote Sensing*, 12 (3): (2020).
4. Digra, M., Dhir, R., and Sharma, N., "Land use land cover classification of remote sensing images based on the deep learning approaches: a statistical analysis and review", *Arabian Journal Of Geosciences*, 15 (10): (2022).
5. Huang, X., Zhang, B., Perrie, W., Lu, Y., and Wang, C., "A novel deep learning method for marine oil spill detection from satellite synthetic aperture radar imagery", *Marine Pollution Bulletin*, 179: (2022).
6. Zhao, S., Luo, Y., Zhang, T., Guo, W., and Zhang, Z., "Active Learning SAR Image Classification Method Crossing Different Imaging Platforms", *IEEE Geoscience And Remote Sensing Letters*, 19: (2022).
7. Sannapu, A. R., Nayak, P., Charan, U. R., Keshava G, S., and Krishnan Naidu, S., "Classification of Marine Vessels using Deep Learning Models based on SAR Images", *International Conference on Inventive Computation Technologies (ICICT)* (2022).
8. Miikkulainen, R., Liang, J., Meyerson, E., Rawal, A., Fink, D., Francon, O., Raju, B., Shahrzad, H., Navruzyan, A., Duffy, N., and Hodjat, B., "Evolving deep neural networks", *Artificial Intelligence in the Age of Neural Networks and Brain Computing* (2018).
9. Xiao, X., Wei, G., Zhou, L., Pan, Y., Jing, H., Zhao, E., and Yuan, Y., "Treatment initiation prediction by EHR mapped PPD tensor based convolutional neural networks boosting algorithm", *Journal Of Biomedical Informatics*, 120: (2021).
10. Passah, A., Sur, S. N., Paul, B., and Kandar, D., "SAR Image Classification: A Comprehensive Study and Analysis", *IEEE Access*, 10: (2022).

11. Zhu, X. X., Montazeri, S., Ali, M., Hua, Y., Wang, Y., Mou, L., Shi, Y., Xu, F., and Bamler, R., "Deep Learning Meets SAR: Concepts, models, pitfalls, and perspectives", *IEEE Geoscience And Remote Sensing Magazine*, 9 (4): (2021).
12. El Housseini, A., Toumi, A., and Khenchaf, A., "Deep Learning for target recognition from SAR images", *Seminar on Detection Systems Architectures and Technologies (DAT)* (2017).
13. Furukawa, H., "Deep Learning for Target Classification Invariance", *arXiv preprint* (2017).
14. Wang, J., Zheng, T., Lei, P., and Bai, X., "Ground Target Classification in Noisy SAR Images Using Convolutional Neural Networks", *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 11 (11): (2018).
15. Wang, Y., Wang, C., and Zhang, H., "Ship classification in high-resolution SAR images using deep learning of small datasets", *Sensors (Switzerland)*, 18 (9): (2018).
16. Lu, C. and Li, W., "Ship classification in high-resolution SAR images via transfer learning with small training dataset", *Sensors (Switzerland)*, 19 (1): (2019).
17. Wu, Z., Hou, B., Ren, B., Ren, Z., Wang, S., and Jiao, L., "A deep detection network based on interaction of instance segmentation and object detection for sar images", *Remote Sensing*, 13 (13): (2021).
18. Sun, Y., Wang, Z., Sun, X., and Fu, K., "SPAN: Strong Scattering Point Aware Network for Ship Detection and Classification in Large-Scale SAR Imagery", *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 15: (2022).
19. Yaohua, X. and Xudong, M., "A SAR oil spill image recognition method based on densenet convolutional neural network", *International Conference on Robots & Intelligent System (ICRIS)* (2019).
20. Bianchi, F. M., Espeseth, M. M., and Borch, N., "Large-scale detection and categorization of oil spills from sar images with deep learning", *Remote Sensing*, 12 (14): (2020).
21. Aghaei, N., Akbarizadeh, G., and Kosarian, A., "Osdes_net: oil spill detection based on efficient_shuffle network using synthetic aperture radar imagery", *Geocarto International*, 37 (26): (2022).
22. Kattenborn, T., Leitloff, J., Schiefer, F., and Hinz, S., "Review on Convolutional Neural Networks (CNN) in vegetation remote sensing." *ISPRS Journal of Photogrammetry and Remote Sensing* 173: (2021).
23. Li, X., Zhang, G., Cui, H., Hou, S., Wang, S., Li, X., Chen, Y., Li, Z., and Zhang, L., "MCANet: A joint semantic segmentation framework of optical and SAR

- images for land use classification", *International Journal Of Applied Earth Observation And Geoinformation*, 106: (2022).
24. Pradhan, B., Al-Najjar, H. A. H., Sameen, M. I., Tsang, I., and Alamri, A. M., "Unseen land cover classification from high-resolution orthophotos using integration of zero-shot learning and convolutional neural networks", *Remote Sensing*, 12 (10): (2020).
 25. Huang, Z., Dumitru, C. O., Pan, Z., Lei, B., and Datcu, M., "Classification of Large-Scale High-Resolution SAR Images with Deep Transfer Learning", *IEEE Geoscience And Remote Sensing Letters*, 18 (1): (2021).
 26. Liang, W., Wu, Y., Li, M., Cao, Y., and Hu, X., "High-resolution SAR image classification using multi-scale deep feature fusion and covariance pooling manifold network", *Remote Sensing*, 13 (2): (2021).
 27. Kang, W., Xiang, Y., Wang, F., and You, H., "CFNet: A Cross Fusion Network for Joint Land Cover Classification Using Optical and SAR Images", *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 15: (2022).
 28. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., and Johnson, B. A., "Deep learning in remote sensing applications: A meta-analysis and review." *ISPRS Journal of Photogrammetry and Remote Sensing*, 152: (2019).
 29. Abdollahi, A. and Pradhan, B., "Integrated technique of segmentation and classification methods with connected components analysis for road extraction from orthophoto images", *Expert Systems With Applications*, 176: (2021).
 30. Internet: TerraSAR-X Archive, <https://terrasar-x-archive.terrasar.com>
 31. Ozcan, C., Sen, B., and Nar, F., "Sparsity-driven despeckling for SAR images", *IEEE Geoscience And Remote Sensing Letters*, 13 (1): (2016).
 32. Silveira, M. and Heleno, S., "Separation between water and land in sar images using region-based level sets", *IEEE Geoscience And Remote Sensing Letters*, 6 (3): (2009).
 33. Molini, A. B., Valsesia, D., Fracastoro, G., and Magli, E., "Speckle2Void: Deep Self-Supervised SAR Despeckling with Blind-Spot Convolutional Neural Networks", *IEEE Transactions On Geoscience And Remote Sensing*, 60: (2022).
 34. Sebastianelli, A., Rosso, M. P. Del, Ullo, S. L., and Gamba, P., "A Speckle Filter for Sentinel-1 SAR Ground Range Detected Data Based on Residual Convolutional Neural Networks", *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 15: (2022).

35. Dalsasso, E., Denis, L., and Tupin, F., "SAR2SAR: A Semi-Supervised Despeckling Algorithm for SAR Images", *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 14: (2021).
36. Meraoumia, I., Dalsasso, E., Denis, L., Abergel, R., and Tupin, F., "Multitemporal Speckle Reduction With Self-Supervised Deep Neural Networks", *IEEE Transactions On Geoscience And Remote Sensing*, 61: (2023).
37. Yu, X., Wu, X., Luo, C., and Ren, P., "Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework", *GIScience And Remote Sensing*, 54 (5): (2017).
38. Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet classification with deep convolutional neural networks", *Advances in Neural Information Processing Systems*, 25: (2012).
39. Jia Deng, Wei Dong, Socher, R., Li-Jia Li, Kai Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database", *Conference on Computer Vision and Pattern Recognition*, 248-255 (2009).
40. Simonyan, K. and Zisserman, A., "Very deep convolutional networks for large-scale image recognition", *3rd International Conference on Learning Representations*, 1-14 (2015).
41. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., "Going deeper with convolutions", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9 (2015).
42. Ioffe, S. and Szegedy, C., "Batch normalization: Accelerating deep network training by reducing internal covariate shift", In *International Conference on Machine Learning*, 448-456 (2015).
43. Dhillon, A. and Verma, G. K., "Convolutional neural network: a review of models, methodologies and applications to object detection.", *Progress in Artificial Intelligence*, 9(2), 85-112 (2020).
44. He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778 (2016).
45. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", *CoRR*, abs/1704.04861: (2017).
46. Tan, M. and Le, Q. V., "EfficientNet: Rethinking model scaling for convolutional neural networks", *International Conference on Machine Learning* (2019).
47. Huang, G., Liu, Z., and Weinberger, K. Q., "Densely Connected Convolutional Networks", *CoRR*, abs/1608.06993: (2016).

48. Gui, Y., Xue, L., and Li, X., "SAR image despeckling using a dilated densely connected network", *Remote Sensing Letters*, 9 (9): (2018).
49. Novelli, A., Aguilar, M. A., Aguilar, F. J., Nemmaoui, A., and Tarantino, E., "AssesSeg—A command line tool to quantify image segmentation quality: A test carried out in southern Spain from satellite imagery." *Remote Sensing*, 9.1 (2017).
50. Argenti, F., Lapini, A., Alparone, L., and Bianchi, T., "A tutorial on speckle reduction in synthetic aperture radar images", *IEEE Geoscience And Remote Sensing Magazine*, 1 (3): (2013).

ÖZGEÇMİŞ

Elif MEŞECİ ilk, orta ve lise öğrenimini aynı şehirde tamamladı. 2016 yılında Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü'nde lisans öğrenimine başladı. 2021 yılında lisans eğitimini tamamlayarak onur derecesi ile mezun oldu. Kasım 2021 ve Ocak 2022 tarihleri arasında Karabük Üniversitesi Teknoloji Geliştirme Bölgesi'nde bulunan SimurgAI Yazılım Tasarım ve Danışmanlık Hizmetleri Limited Şirketi'nde Yapay Zeka Geliştiricisi olarak görev yaptı. 2021 yılında Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü'nde yüksek lisans öğrenimine başladı. Bu süreçte sağlık görüntüleri ve SAR görüntüleri üzerine derin öğrenme alanında çalışmalar gerçekleştirerek bildiri yayınladı. Şu anda, Zonguldak Bülent Ecevit Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Şubat 2022 tarihi itibarıyla Araştırma Görevlisi olarak görev yapmaktadır.