

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK
LİSANS PROGRAMI

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ İLE UYDU
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

HAZIRLAYAN

CANBERK AYDEMİR

YÜKSEK LİSANS TEZİ

ANKARA - 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK
LİSANS PROGRAMI

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ İLE UYDU
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

HAZIRLAYAN

CANBERK AYDEMİR

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ SELDA GÜNEY

ANKARA – 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Canberk Aydemir tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 05/01/2022

Tez Adı: Derin Öğrenme ve Makine Öğrenmesi ile Uydu Görüntülerinin Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı- Soyadı, Kurumu)

İmza

Prof. Dr. Hasan Şakir Bilge, Gazi Üniversitesi

.....

Prof. Dr. Hamit Erdem, Başkent Üniversitesi

.....

Dr. Öğr. Üyesi Selda Güney, Başkent Üniversitesi

.....

ONAY

Prof. Dr. Ömer Faruk Elaldı
Fen Bilimleri Enstitüsü Müdürü

Tarih: / / 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 11/01/2022

Öğrencinin Adı, Soyadı : Canberk Aydemir

Öğrencinin Numarası : 21810042

Anabilim Dalı : Elektrik-Elektronik Mühendisliği

Programı : Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Selda Güney

Tez Başlığı : Derin Öğrenme ve Makine Öğrenmesi ile Uydu Görüntülerinin

Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 77 sayfalık kısmına ilişkin, 11/01/2022 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %6'dır.

Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası :

Onay

Tarih: 11/01/ 2022

Dr. Öğr. Üyesi Selda Güney

TEŞEKKÜR

Lisans ve yüksek lisans eğitimim süresince her zaman bilgisiyle bana yol gösteren, her adımında benden desteğini ve motivasyonunu esirgemeyen, karşılaştığım her probleme cevap veren çok değerli danışman hocam Sayın Dr. Öğr. Üyesi Selda Güney’e en derin saygı ve teşekkürlerimi sunarım.

Hem akademik hayatımda hem de günlük hayatımda benden desteğini esirgemeyen, enerjileriyle moral motivasyonumu her zaman yükselten, takıldığım noktalarda bana daima destek olan Arş. Gör. Büşra Kübra Karaca, Arş. Gör. Burcu Oltu, Arş. Gör. Bekir Göğüş’e teşekkür ederim.

Akademik hayatım ve eğitim hayatım boyunca karşılaştığım her problemde bilgileriyle yolumu aydınlatan, fikirleriyle başarıma anahtar olan Prof. Dr. Hamit Erdem, Arş. Gör. Begüm Cangöz, Arş. Gör. Berkan Tezcan’a teşekkür ederim.

Tanıştığımız günden beri hayatımdaki her zorlukta yanımda olan ve sorgusuz bir şekilde beni destekleyen, fikirleriyle yolumu aydınlatan arkadaşlarım Samet Koyuncu ve Rıdvan Berk Bilgiç’e teşekkürlerimi sunarım.

Çalışmamda kullandığım verilerin setleri için yaptıkları çalışmalarla veri setlerini literatüre sunan Gui-Song Xia ve Patrick Helber’e teşekkür ederim.

Bugün bu başarıları elde etmemde en çok emeği olan, olan tüm eğitim öğretim hayatım boyunca desteğini hiçbir zaman benden esirgemeyen, her zorlandığımda pes etmememi başarabileceğimi söyleyen dedem Ali Aydemir’e teşekkür ederim.

Tüm eğitim hayatım boyunca her zaman arkamda olan, emeklerini bir an olsun esirgemeyen, her türlü fedakarlığı karşılıksız gerçekleştiren ve başarılarımla her zaman gurur duyan aileme ve yakınlarıma teşekkür ederim.

ÖZET

Canberk AYDEMİR

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ İLE UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2022

Uzaktan algılama günümüzde afet tespiti, iklim değişiklikleri, kentsel değişimler gibi birçok doğal farklılığın tespitinde büyük öneme sahiptir. Teknolojideki görüntüleme alanında meydana gelen gelişmeler sonucunda uzaktan algılama günümüzde çok popüler bir konu haline gelmiştir. Gelişen teknolojilerin sağladığı en büyük fayda günümüzde uzaktan algılama için kullanılan verilerin kolay erişilebilir hale gelmiş olmasıdır. Uzaktan algılama işlemi ortamın fiziksel ve konumsal bilgileri gibi ayırt edici özelliklerinin algılanması işlemi olarak adlandırılabilir. Algılama işlemlerinde başarıyı en çok etkileyen faktörlerden birisi çözünürlüktür. Çözünürlüğün gereken seviyeden düşük olması ayırt edilmek istenen nesnelerin özelliklerinin anlaşılamaz hale gelmesine sebep olmakta ve bu nedenle ayırt etme işleminin önünde büyük bir engel teşkil etmektedir. Günümüzde derin öğrenme yöntemlerinin uzaktan algılama verilerinin sınıflandırılmasında oldukça popüler ve başarılı olduğu görülmektedir. Derin öğrenme ağları kullanılarak görüntü özelliklerinin öğrenilmesi ve sınıflandırma için gerekli özniteliklerin çıkarılması alanında başarılı sonuçlar elde edilmektedir. Uydu görüntüsü sınıflandırma işleminde karşılaşılan bir diğer problem sınıflandırma için yeterli verinin elde edilememesidir.

Bu çalışmada uydu görüntülerinin sınıflandırılması için derin öğrenme ve makine öğrenmesi metodları kullanılmıştır. Yapılan analizler EuroSAT, AID ve iki veri setinin uygun koşullar altında birleştirilmesiyle oluşturulmuş bir birleşik veri seti üzerinde gerçekleştirilmiştir. Veri seti birleştirme işlemimizdeki temel amaç uydu görüntüsü sınıflandırma işleminde artan sınıf sayısına göre sınıflandırma başarısındaki değişiklikleri gözlemlemektir. Bu tez çalışması kapsamında iki veri seti derin öğrenme ağları kullanılarak ayrı ayrı analiz edilmiştir. Buna ek olarak birleşik veri seti hem derin öğrenme hem de makine öğrenmesi yöntemleri kullanılarak analiz edilmiştir. Bu işlemin amacı oluşturulan veri seti üzerinde makine öğrenmesi ve derin öğrenme temelli sınıflandırıcıların karşılaştırılmasıdır. Yapılan analizler

sonucunda EuroSAT veri seti için en yüksek sınıflandırma başarısı %98.11 doğruluk oranı ile DenseNet-201 derin öğrenme ağı kullanılarak elde edilmiştir. AID veri seti için en başarılı sınıflandırıcı %96.10 doğruluk oranı ile DenseNet-201 derin öğrenme ağıdır. Çalışma kapsamında birleştirilen veri seti için yapılan analizlerde uygulanan sınıflandırma metotları arasında en başarılı sınıflandırıcı %96.20 doğruluk oranı ile yine DenseNet-201 derin öğrenme ağı olarak gözlenmektedir. Veri setleri birleştirilerek oluşturulan birleşik veri setinde başarı oranının AID veri setinde göre daha yüksek çıktığı görülmektedir.

ANAHTAR KELİMELER: Uzaktan Algılama, Uydu Görüntüsü, Aktarımlı Öğrenme, Makine Öğrenmesi, Sınıflandırma



ABSTRACT

Canberk AYDEMİR

CLASSIFICATION OF SATELLITE IMAGES WITH DEEP LEARNING AND MACHINE LEARNING

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2022

Remote sensing is of great importance in the detection of many natural differences such as disaster detection, climate changes and urban changes. As a result of the developments in the field of imaging in technology, remote sensing has become a very popular topic today. The biggest benefit provided by the developing technologies is that the data used for remote sensing has become easily accessible today. Remote sensing can be explained as the process of detecting the distinctive features of the environment, such as physical and spatial information. One of the most influential factors on success in detection processes is resolution. The resolution being lower than the required level causes the features of the objects to be differentiated to become incomprehensible and therefore constitutes a major obstacle to the detection process. Today, deep learning methods seem to be very popular and successful in classifying remote sensing data. Successful results are obtained in the field of learning image features and extracting the necessary features for classification using deep learning networks. Another difficulty in satellite image classification is the inability to obtain enough data for classification.

In this study, deep learning and machine learning methods were used to classify satellite images. The analyzes were performed on EuroSAT, AID and a combined dataset created by combining two datasets under appropriate conditions. The main purpose of our data set merging process is to observe the changes in classification success according to the increasing number of classes in the satellite image classification process. In this thesis, two data sets were analyzed separately using deep learning networks. In addition, the combined data set was analyzed using both deep learning and machine learning methods. The purpose of this process is to compare machine learning and deep learning based classifiers on the created data set. As a result of the analysis, the highest classification success for the EuroSAT dataset was obtained using the DenseNet-201 deep learning network with an

accuracy rate of 98.11%. The classifier with the highest accuracy for the AID dataset is the DenseNet-201 deep learning network with an accuracy rate of 96.10%. Among the classification methods applied in the analysis for the combined data set, the classifier with the highest accuracy is observed as the DenseNet-201 deep learning network, with an accuracy rate of 96.20%. It is seen that the success rate in the combined dataset is higher than in the AID dataset.

KEYWORDS: Remote Sensing, Satellite Image, Transfer Learning, Machine Learning, Classification



İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ	1
1.1. Çalışmanın Konusu.....	1
1.2. Çalışmanın Amacı ve Önemi.....	2
1.3. Literatür Özeti	3
1.4. Genel Bakış	7
2. KURAMSAL TEMELLER	8
2.1. Uydu Görüntüleri.....	8
2.1.1. Sayısal Görüntü	8
2.1.2. Çözünürlük	9
2.1.3. Uydu görüntüleme sensörleri	9
2.1.4. Uydu görüntülerinde çözünürlük	10
2.1.5. Uydu görüntülerinde bozulma	11
2.2. Uzaktan Algılama.....	11
2.2.1. Uzaktan algılama aşamaları.....	12
2.2.2. Uzaktan algılayıcı uzay platformları.....	12
2.2.3. Dünya ve gezegen atmosferleri yoluyla iletim	13
2.2.4. Elektromanyetik Spektrum.....	13
2.2.5. Atmosfer ile enerji etkileşimleri.....	14

2.2.6. Dünya yüzey özellikleri ile enerji etkileşimi	14
2.2.7. Nesnelerin Spektral Yansımaları	15
2.3. Sınıflandırma	16
2.3.1. Denetimli öğrenme	16
2.3.2. Denetimsiz Öğrenme	17
3. VERİ SETİ	18
3.1. Giriş	18
3.2. Örnek Alanları	18
3.3. Kullanılan Veri Setleri	19
3.3.1. EuroSAT veri seti	20
3.3.2. AID veri seti	20
3.3.3. Veri setlerinin birleştirilmesi	20
4. MATERYAL VE METOT	22
4.1. Derin Öğrenme	22
4.2. Öznitelik Çıkarma	22
4.3. Transfer Öğrenmesi Tabanlı Sınıflandırma	23
4.3.1. DenseNet-201	24
4.3.2. AlexNet	25
4.3.3. GoogLeNet	26
4.3.4. ResNet	28
4.3.5. MobileNetV2	29
4.3.6. VGG-16	30
4.4. Makine Öğrenmesi Tabanlı Sınıflandırma	32
4.4.1. Karar Ağaçları	32
4.4.2. Destek vektör makineleri	33
4.4.3. K-en yakın komşuluk algoritması	34
4.4.4. Naive Bayes	35
4.4.5. Topluluk Metotları	36
4.5. Sınıflandırma Başarısının Değerlendirilmesi	36

5. DENEYSEL ÇALIŞMA VE SONUÇLAR.....	38
5.1. EuroSAT Veri Seti İçin Sınıflandırma Sonuçları	39
5.2. AID Veri Seti İçin Sınıflandırma Sonuçları	41
5.3. Birleşik Veri Seti İçin Sınıflandırma Sonuçları	42
5.3.1. Birleşik veri seti için derin öğrenme tabanlı sınıflandırma sonuçları	43
5.3.2. Birleşik veri seti için makine öğrenmesi tabanlı sınıflandırma sonuçları	44
6. SONUÇ VE ÖNERİLER.....	52
7. KAYNAKÇA.....	54



TABLÖLER LİSTESİ

	Sayfa
Tablo 4.1.Karışıklık matrisi.....	37
Tablo 5.1. EuroSAT veri seti sınıflandırma sonuçları.....	40
Tablo 5.2. AID veri seti sınıflandırma sonuçları	42
Tablo 5.3. Birleşik veri seti sınıflandırma sonuçları	44
Tablo 5.4. Birleşik veri seti için DenseNet-201 kullanılarak çıkarılan öznitelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları	45
Tablo 5.5. Birleşik veri seti için ResNet-18 kullanılarak çıkarılan öznitelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları.....	47
Tablo 5.6. Birleşik veri seti için AlexNet kullanılarak çıkarılan öznitelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları.....	49
Tablo 5.7.Literatürde yapılan çalışmalar ve başarı sonuçları.....	51

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Aktif ve pasif sensör konsepti [27].....	10
Şekil 2.2.Uzaktan algılama işlemi	12
Şekil 2.3. Dalga yapısı [30]	13
Şekil 2.4. Elektromanyetik spektrum [31].....	14
Şekil 2.5. Dünya yüzeyi ile enerji etkileşimi [30]	15
Şekil 2.6. Bazı nesnelerin spektral yansımaları [23]	16
Şekil 3.1. EuroSAT veri seti [14]	18
Şekil 3.2. AID veri seti [8]	19
Şekil 4.1. Esa mimarisi [39]	23
Şekil 4.2. DenseNet-201 ağ yapısı [45].....	25
Şekil 4.3. AlexNet ağ yapısı [49]	26
Şekil 4.4. GoogLeNet ağ yapısı [54]	27
Şekil 4.5. Başlangıç modülü [54]	28
Şekil 4.6. ResNet-18 ağ yapısı [58].....	29
Şekil 4.7. MobileNetV2 ağ yapısı [65].....	29
Şekil 4.8. VGG-16 ağ yapısı [68]	31
Şekil 4.9. Karar ağacı yapısı [73]	33
Şekil 4.10. İki boyutlu uzayda hiperdüzlemler.....	34
Şekil 4.11. KNN sınıflandırıcı örneği [80]	35
Şekil 5.1.Uydu görüntülerinin sınıflandırma blok şeması.....	39
Şekil 5.2. EuroSAT veri için DenseNet-201 derin ağı sınıflandırma uygulaması	40
Şekil 5.3. AID veri seti için DenseNet-201 derin ağı sınıflandırma uygulaması	42
Şekil 5.4. Birleşik veri seti için DenseNet-201 derin ağı uygulaması.....	44
Şekil 5.5. Birleşik veri seti için DenseNet-201 kullanılarak çıkarılan öznelilikler ile topluluk metotları uygulaması karmaşıklık matrisi	46
Şekil 5.6. Birleşik veri seti için ResNet-18 kullanılarak çıkarılan öznelilikler ile topluluk metotları uygulaması karmaşıklık matrisi.....	48
Şekil 5.7. Birleşik veri seti için AlexNet kullanılarak çıkarılan öznelilikler ile topluluk metotları uygulaması karmaşıklık matrisi.....	50

SİMGELER VE KISALTMALAR

EMR	Elektromanyetik Radyasyon
AID	Aerial Image Dataset (Hava Görüntüleri Veri Seti)
ESA	Evrişimsel Sinir Ağları
TSC	A Two-Layer Sparse Coding (İki Katmanlı Seyrek Kodlama)
KNN	K En Yakın Komşu
DVM	Destek Vektör Makineleri
NB	Naive Bayes
IRS	Indian Remote Sensing (Hint Uzaktan Algılama)
FCN	Fully Convolutional Network (Tam Evrişimsel Ağ)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
GAN	Generative Adversarial Network (Üretken Çelişki Ağı)
NDVI	The Normalized Differance Vegetation Index (Normalleştirilmiş Fark Bitki Örtüsü İndeksi)
PCA	Principle Component Analysis (Temel Bileşen Analizi)
LGBPHS	Local Gabor Binary Pattern Histogram Sequence (Yerel Gabor İkili Desen Histogram Dizisi)
HOG	Histogram of Oriented Gradient (Yönlendirilmiş Gradyan Histogramı)
LULC	Land Use Ladn Cover (Arazi Kullanımı Arazi Örtüsü)
LSTM	Long Short Term Memory (Uzun Kısa Süreli Bellek)
PSO	Particle Swatm Optimization (Parçacık Sürüsü Optimizasyonu)
BR	Blue Ratio (Mavi Oranı)
DSA	Derin Sinir Ağları
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif

1. GİRİŞ

1.1. Çalışmanın Konusu

Uzaktan algılama 1960 yıllarının ilk dönemlerinde tanıtılan bir tekniktir. Uzaktan algılama görüntüleri diğer görüntülere kıyasla zamansal frekans olarak yüksek ve geniş coğrafi alanları kapsamaktadır. Geçtiğimiz yıllarda teknolojiye meydana gelen hızlı gelişmeler sonucunda günümüzde uzaktan algılama oldukça popüler ve önemli konular arasına girdi. Gelişen teknoloji sayesinde uzaktan algılama alanında kullanılan veriler çok daha erişilebilir hale geldi [1], [2]. Uzaktan algılama temel olarak uydu araçları, görüntü alınması mümkün hava araçları ve uzaktan görüntü alabilen yer araçları gibi araçlar yardımı ile elde edilen görüntülerden yararlanılarak bir ortamın fiziksel veya konumsal bilgileri gibi ayırt edici özelliklerin algılanması işlemi olarak adlandırılabilir. Bu algılama işleminde yüzeyin veya nesnenin ayırt edici özelliklerinin doğru ve işlenebilir şekilde elde edilmesi yapılacak analizler ve nesne tespit gibi uygulamalar için oldukça önem arz etmektedir. Uzaktan algılamada kullanılan araçlar tarafından elde edilen görüntülerin çözünürlüğü önemlidir. Çözünürlüğün düşük olması özelliklerin anlaşılabilir ve ayırt edilemez hale gelmesine sebep olurken çözünürlüğün ihtiyaç duyulanın üstünde olması durumu ise yapılacak analizler için işlem yükünü artırmaktadır. Gelişen görüntüleme teknolojisi ile artan çözünürlük sayesinde uzaktan algılama amacıyla elde edilen görüntülerde nesneler çok daha ayırt edilebilir ve sınıflandırma için çok daha kullanışlı hale gelmiştir [3]. Uzaktan algılama teknolojisinde görüntü erişiminde meydana gelen bu kolaylıklar sınıflandırma çalışması üzerine çalışan uzmanların oldukça ilgisini çekmektedir. Sınıflandırma çalışmaları gerek modern uygulamalar gerekse piksel temelli incelemelerde bulunan geleneksel uygulamalar alanında ulaşılabilen veriler sayesinde büyük ilerlemeler kat etmektedir. Bu alanda uzaktan algılama ve uydu görüntüsü veri setlerinden faydalanılarak endüstriyel yapı tespiti, arazi örtüsü sınıflandırması, doğal alan sınıflandırması, iklim değişikliği tespitleri gibi birçok sınıflandırma çalışması yapılması mümkündür [2], [4].

Günümüz teknolojisinde Derin Öğrenme yöntemlerinin uzaktan algılama alanındaki verileri sınıflandırmada oldukça başarılı olduğu görülmüştür. Derin öğrenme yöntemleri ile görüntü özelliklerinin başarılı bir şekilde öğrenilmesi ve sınıflandırma için uygun özelliklerin elde edilmesi alanında etkileyici başarılar elde edilmiştir. Derin öğrenme yöntemlerinden en yaygın olanlarından birisi Evrimsel Sinir Ağlarıdır (ESA, CNN, Convolutional Neural Network). ESA mimarileri sınıflandırma için uygunluğunu kanıtlamış

ve son yıllarda görüntü sınıflandırma ve nesne tespit işlemlerinde oldukça yaygın olarak kullanılmaktadır [3], [5]. ESA yapısının çalışması incelendiğinde işlem sürelerinin makul hale getirilmesi için küçük sabit boyutlu görüntüler gerekmektedir. Bu nedenle görüntülerde boyut küçültme gibi işlemler gerekli olabilmektedir. Normal görüntülerde bu işlemler önemli özellikleri koruyabilmektedir. Ancak uydu görüntülerinde durum normal görüntülerden farklıdır çünkü nesneler ve tespit edilmek istenen ortamlar örneğin bir havalimanı pistindeki uçak gibi sıradan görüntülerdeki nesne ve ortamlardan çok daha büyük olabilmektedir [5].

1.2. Çalışmanın Amacı ve Önemi

Bu çalışmada, uzaktan algılama amacıyla kullanılan uydu görüntüleri üzerinde sınıflandırma çalışmaları amaçlanmaktadır. Derin öğrenme ağları ile birlikte derin öğrenme ağları kullanılarak çıkarılmış öznitelikler yardımıyla makine öğrenmesi algoritmaları kullanılarak iki farklı yöntem arasındaki başarının incelenmesi ve sınıflandırma başarısının artan sınıf sayısına rağmen iyileştirilmesi amaçlanmıştır. Bu tez kapsamında transfer öğrenmesi tabanlı sınıflandırma amacıyla önceden eğitilmiş olarak altı farklı derin öğrenme ağı (AlexNet, GoogLeNet, VGG-16, ResNet-18, MobileNetV2, DenseNet-201) yaklaşımı kullanılmıştır. Kullanılan yöntemler EuroSAT ve Hava Görüntüsü Veri Kümesi (AID, Aerial Image Dataset) olmak üzere iki veri setinde ayrı ayrı denenmiştir. Buna ek olarak sınıf sayısındaki artışa karşılık gelen sınıflandırma başarısındaki değişimi gözlemlemek amacıyla iki veri setinin uygun şartlar altında birleştirilmesinden bir bileşik veri seti oluşturulmuştur. Veri setlerindeki ayrı ayrı yürütülen çalışmalar dışında birleşik veri seti üzerinde hem derin öğrenme ağları hem de derin öğrenme ile çıkarılan özniteliklerden faydalanarak makine öğrenmesi algoritmaları uygulanmıştır. Bu uygulamaların amacı hem sınıf sayısındaki artışa göre sınıflandırma başarısındaki değişimi hem de derin öğrenme ve makine öğrenmesi tabanlı sınıflandırma arasındaki başarı oranı değişimini gözlemlemektir.

Uzaktan algılama ve uydu görüntülerinin sınıflandırması tarım, iklimsel değişimler, afet müdahaleleri, kentsel değişimler gibi birçok alanda sınıflandırmaya elverişlidir. Bu nedenle önemli ve kritik müdahale gerektiren problemler ve tespitler için uzaktan algılama yüksek önem arz etmektedir. Ulaşım uzak fark edilmesi güç alanlarda meydana gelen afet gibi durumların hızlıca tespitinde uzaktan algılama önemli rol oynamaktadır.

1.3. Literatür Özeti

2011 Yılında Dai et al., çalışmalarında uydu görüntüleri tabanlı sınıflandırma işlemine görsel dikkati dahil etmek ve öğrenme aşaması olmadan uydu görüntüsü sınıflandırma konularına değinmektedir. Görüntülerin gerçek komşularını keşfetmek ve yoğun öğrenme kısmını atlamak amacıyla iki katmanlı seyrek kodlama (a two-layer sparse coding, TSC) modeli tasarlanmıştır. Analizler için Google Earth sisteminden 12 sınıf etiketine ait görüntüler toplanarak veri seti oluşturulmuştur. Veri seti üzerinde yapılan analizlerde K-en yakın komşuluk algoritmaları (KNN, K-nearest neighbor algorithms), Destek Vektör Makineleri (DVM, Support Vector Machine, SVM) ve TSC metotları uygulanmış ve en yüksek başarı oranının DVM metodu ile %84.7 olarak elde edildiği görülmektedir. TSC metodu DVM ile çok yakın olarak eğitimsiz bir sınıflandırma işleminde %84.2 başarı oranı elde etmektedir [6].

2011 yılında Moorthi et al., uydu görüntülerinin sınıflandırılması amacıyla makine öğrenmesi tabanlı Destek Vektör Makineleri metodunu ele almaktadırlar. Çalışmada gözlenen amaç DVM ile Geleneksel sınıflandırma yöntemleri arasında başarı kıyaslaması yapmaktır. Analizlerin gerçekleştirilmesi için Resorucesat-1, Indian Remote Sensing (IRS) platformlarından alınan LISS-3 ve AWIFS sensör verileri kullanılmaktadır. Yapılan analizler sonucunda DVM uygulamasının %92.84 başarı oranı ile analizler arasındaki en başarılı sınıflandırma sonucunu elde ettiği gözlenmektedir [7].

2016 yılında Xia et al., çalışmalarında AID veri kümesini açıklamaktadır. Geniş kapsamlı bir veri seti oluşturmak için 10.000 den fazla görüntü toplanmış ve bu görüntülere açıklamalar eklenmiştir. Veri seti üzerinde düşük-seviye, orta-seviye, yüksek-seviye metotlar (CaffeNet, VGG-VD-16, GoogLeNet) denenmiştir. Yapılan analizler sonucunda en yüksek sınıflandırma başarısının %89.64 olarak VGG-VD-16 derin öğrenme ağı kullanılarak elde edildiği gözlemlenmektedir [8].

2016 yılında Minu et al., kapsamlı uydu görüntülerinin sınıflandırılması amacıyla denetimli sınıflandırmanın farklı yöntemlerini, belirli sınıflandırma sonrası teknikleri ve spektral bağlamsal sınıflandırmayı analiz etmektedir. En Boy Kapsamlı Yaklaşım (ACA) düşük ve yüksek kompleksliğe sahip ortam görüntülerinde analiz edilmiştir. ACA Paralelepiped, ACA Minimum Mesafe, Naive Bayes ve K-En Yakın Komşuluk algoritması analizler için kullanılmış ve en yüksek sınıflandırma başarısının düşük kompleksliğe sahip görüntüler üzerinde ACA Paralelepiped uygulaması ile %89.15 olarak elde edildiği görülmektedir [2].

2017 yılında Maggiori et al., uydu görüntülerinin piksel bazında sınıflandırılması amacıyla ESA yapısını ele alan bir çalışma gerçekleştirmiştir. ESA yapıları örnek verilerin sınıflandırma haritalarını üretmek amacıyla eğitilmiştir. ESA yapıları başlangıçta referans bakımından yanlış veriler kullanılarak başlatılmakta devamında az miktarda doğru sınıf etiketine sahip veri eklenmektedir. Bu işlemdeki amaç kusurlu verilerden kaynaklanan problemleri minimize etmektir. Çalışmalar Fransa'nın Forez bölgesinde bir Pleiades görüntüsü üzerinde gerçekleştirilmektedir. Analiz metodu olarak Tam Evrişimsel Ağlar (FCN, Fully Convolutional Network) ve İki Ölçekli Tam Evrişimsel Ağları (Two-scale FCN) kullanılmaktadır. Çalışmada en yüksek başarı oranının Two-scale FCN kullanılarak %99.573 olarak elde edildiği görülmektedir [9].

2017 yılında Maggiori et al., uydu görüntüsü sınıflandırma işleminde sınıflandırma haritalarının kalitesini artırmak amacıyla ESA yapılarına ek olarak bir Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN) önermektedir. Kendi oluşturdukları 3 sınıf etiketine sahip veri setinde ESA ile RNN yapılarının birlikte kullanıldığında %98.24 sınıflandırma başarısı olduğunu anca ESA yapısını tek başına kullandıklarında %96.72 sınıflandırma başarısı elde edildiğini gözlemlemişlerdir ve RNN yapısının eklenmesi ile başarıdaki artışı kanıtlamışlardır [10].

2018 yılında Duarte et al., bina hasarlarının belirlenmesi amacıyla ESA ya dayanan modeller kullanarak çalışmalarını gerçekleştirmişlerdir. Çalışmada hem insanlı hem de insansız görüntü örnekleri dikkate alan bir ESA yapısı kullanılmıştır. Manned ve UAV platformlarından toplanan görüntüler üzerinde yapılan analizlerde benchmark, benchmark_ft, mresA, mresB, mresC ağları kullanılmıştır ve en yüksek sınıflandırma başarısı %94.40 ile mresC ağı kullanılarak yapılan analizlerde elde edildiği görülmektedir [11].

2018 yılında Roy et al., ulaşım açık uydu görüntülerindeki etiketli veri azlığından kaynaklı darboğaz problemleriyle başa çıkmak amacıyla yarı denetimli Üretken Çelişki Ağı (Generative Adversarial Network, GAN) sınıflandırıcısını önermektedir. Çalışmalarda ImageNet veri seti kullanılmıştır. Yalnızca 100 etiketli görüntü kullanılarak %69 a yakın bir başarının GAN ağ yapısı ile elde edildiği görülmektedir. Çalışmada GAN yapısına ek olarak ESA ve Inception Net ağ yapıları da kullanılmış ancak başarı oranları daha düşük gözlenmektedir. ESA yapısı ile yapılan analizlerde %29.3 ve Inception Net ile yapılan analizlerde %63.9 başarı oranı elde edilmektedir [12].

2018 yılında Unnikrishnan et al., uydu görüntülerinin sınıflandırılması amacıyla ESA temelli derin öğrenme ağlarını değerlendirmektedir. Normalleştirilmiş Fark Bitki Örtüsü

İndeksi(The Normalized Difference Vegetation Index, NDVI) arazi örtüsünü tespit etmek amacıyla kullanılmaktadır. NDVI görüntüleri parçalayarak yeşil bitki örtüsünün varlığını veya yokluğunu araştırmak amacıyla kullanılmaktadır. Deneysel çalışmalar SAT-4 veri seti üzerinde gerçekleştirilmiştir. Çalışmada sınıflandırma için AlexNet derin öğrenme ağından faydalanılmaktadır ve sınıflandırma başarısı %98.76 olarak gözlenmektedir [13].

2019 yılında Helber et al., yapmış oldukları çalışmalarında Sentinel-2 uydu görüntülerinden faydalanarak 27.000 etiketli görüntü ve 10 sınıf etiketine sahip EuroSAT veri setini sunmuşlardır. Çalışmada EuroSAT veri seti üzerinde en başarılı sınıflandırma sonuçları ResNet-50 modeli ile %98.57 olarak elde edilmiştir. Buna ek olarak çalışmada UC Merced, AID, SAT-6, BCS veri setleri üzerinde ESA (üç katmanlı), GoogLeNet, ResNet-50 olmak üzere 3 model ile analizler gerçekleştirilmiştir. UC Merced veri setinde %93.8 başarı oranı ile en başarılı model GoogLeNet olarak gözlenmektedir. AID veri seti için gerçekleştirilen analizlerde ResNet-50 %83.70 başarı oranında kalırken GoogLeNet %87.10 ile en yüksek başarı oranına sahiptir. SAT-6 veri seti için gerçekleştirilen analizlerde ResNet-50 %99.35 ile en başarılı sınıflandırmayı gerçekleştirmiştir. BCS veri seti analizleri kapsamında en başarılı sınıflandırıcı ESA (üç katmanlı) yapısı %89.33 başarı oranı elde etmektedir [14].

2019 yılında Liu et al., yapmış oldukları çalışmada SAT-4 ve SAT-6 veri setleri üzerinde geniş kapsamlı uydu görüntülerinin sınıflandırılması amacıyla DeepSat ağını önermektedirler. DeepSat derin öğrenme ağı hesaplanan öznetelikler ve ESA yapısının oluşturduğu özellik haritalarına erişim sağlamaktadır. Yapılan analizler sonucunda SAT-4 veri setinde %99.90 ve SAT-6 veri setinde %99.84 sınıflandırma başarıları elde edildiği gözlenmektedir [15].

2019 yılında Charou et al., tarımsal ve tarım dışı arazi tespiti için ESA ve AlexNet ile transfer öğrenmesine dayalı analizler gerçekleştirilmektedir. Çalışmada Demokritos ve EuroSAT veri setleri üzerinde EuroNet, EuroNet_exp, IonioNet_PI, IonioNet_PD, IonioNet_PE2 metotları kullanılmıştır. EuroSat veri seti için en başarılı sınıflandırıcı EuroNet olarak gözlenirken Demokritos veri seti için en yüksek başarı oranı IonioNet_PE2 sınıflandırıcısı tarafından elde edilmektedir [16].

2019 yılında Rai et al., sundukları çalışmada Landsat 8 veri seti üzerinde görüntü füzyonu kullanılarak multi spektral uydu görüntülerinin sınıflandırılması amacıyla Temel Bileşen Analizi (PCA) ve ESA yöntemleri sunulmaktadır. PCA görüntülerin boyutlarının küçültülmesi amacıyla kullanılmıştır. ESA ile yapılan sınıflandırma işleminde %94.5 sınıflandırma başarısı elde edilmiştir [4].

2020 yılında Yamashkin et al., veri yetersizliği problemlerine karşı derin öğrenme uygulamaları ile yüksek çözünürlüğe sahip uydu görüntülerini sınıflandırma konusuna değinmişlerdir. Çalışmada önerilen GeoSystemNet modelinin temel avantajı esnek konfigürasyona müsait olmasıdır. EuroSAT veri seti üzerinde 2 katmanlı ESA, GoogLeNet, DenseNet121, InceptionV3, ResNet50, ResNet101, VGG16, GeoSystemNet olmak üzere bir çok derin öğrenme ağı denenmiştir. En yüksek sınıflandırma başarısının %97.93 ile InceptionV3 ağı ile elde edildiği gözlemlenirken GeoSystemNet %95.30 başarı oranı elde etmektedir [17].

2020 yılında Kadhim et al., ESA yapıları ile insan erişimi olmadan sınıflandırmayı idare edebilecek sistemler oluşturmak amacıyla bir çalışma gerçekleştirmiştir. Çalışmada AlexNet, VGG19, GoogLeNet ve Resnet50 modelleri kullanılmıştır. Seçilen modeller SAT4, SAT6 ve UC Merced olmak üzere üç farklı veri seti üzerinde analiz edilmiş ve Resnet50 diğer modellere göre daha yüksek başarılar sunmuştur. ResNet-50 modeli ile UC Merced veri seti için %98, SAT4 için %95.8 ve SAT6 için %94.1 başarı oranları elde edildiği gözlenmektedir [1].

2020 yılında Rajendran vd., Arazi Kullanımı Arazi Örtüsü (Land Use Land Cover, LULC) sınıflandırmasının performansını artırmak amacıyla derin öğrenme sınıflandırıcı ile birlikte bir hibrit özellik optimizasyon algoritması önermektedir. Analizler SAT-4 ve SAT-6 veri setleri üzerinde gerçekleştirilmiştir. Verilerden öznitelik çıkarımı amacıyla Yerel Gabor İkili Desen Histogram Dizisi (Local Gabor Binary Pattern Histogram Sequence, LGBPHS), Yönlendirilmiş gradyan (Histogram of Oriented Gradient, HOG) histogramı ve Haralick doku özellikleri kullanılarak bir hibrit optimizasyon gerçekleştirilmektedir. LULC sınıflarını sınıflandırmak amacıyla uzun-kısa süreli bellek (Long short-term memory, LSTM) ağı kullanılmaktadır. Yapılan analizler sonucunda önerilen insan grubu bazlı LSTM kullanılan parçacık sürüsü optimizasyonu (Particle swarm optimization, PSO) yönteminin %99.99 başarı oranı ile çalışmada yer alan diğer LSTM modellerinden ve VGG, AlexNet, ConvNet gibi mevcut modellerden başarılı olduğu gösterilmektedir [18].

2021 yılında Yassine et al., LULC veri analizlerinin daha başarılı sınıflandırılmasını ele alarak çalışmada ESA tabanlı sınıflandırma işlemleri gerçekleştirmektedirler. Uygulamalarda EuroSAT veri setinden elde edilen veriler kullanılmıştır. Çalışmada ESA ile %96.84 sınıflandırma başarısı elde edilmektedir. Çalışmada bu başarı oranını artırmak amacıyla iki yaklaşım sergilenmektedir. İlk yaklaşımda öznitelikler RGB formatı yerine 13 spektral özellik bandından çıkarılarak %98.78 sınıflandırma doğruluğu elde edildiği

görülmektedir. İkinci yaklaşımda ise LULC’de kullanılan Mavi Oranı (Blue Ratio, BR) ve Kırmızı Kenar (Red Edge’e, VIRE) gibi hesaplanmış indekslere ek olarak 13 spektral banttan öznitelikler çıkarılarak %99.58 başarı oranı elde edildiği gözlenmektedir [19].

2021 yılında Pritt et al.,yaptıkları çalışmalarda büyük coğrafi alanları algılamanın derin öğrenme yöntemleriyle geleneksel yöntemlere kıyasla daha başarılı olduğunu ele almaktadır. fMoW veri seti üzerinde 63 farklı sınıf etiketini ve 57.000 görüntüyü sınıflandırma amacıyla ESA yapısı ele alınmıştır. Kullanılan ESA metodu ile %83 sınıflandırma başarısı elde edilmiş ve sınıfların 15’i üzerinde %95 sınıflandırma başarısı elde edilmiştir [5].

1.4. Genel Bakış

Bu çalışma temel olarak 6 bölümden oluşmaktadır ve geçmiş çalışmalara katkı olarak veri setindeki sınıf artışının sınıflandırma başarısına katkısı incelenmiştir. Buna ek olarak derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak sınıflandırma işlemleri gerçekleştirilmiş ve sınıflandırma başarıları karşılaştırılmıştır. İlk bölümde Çalışmanın konusu, amacı ve önemi sunulmaktadır. Buna ek olarak literatür taraması kapsamında çalışmamıza benzer nitelikte uzaktan algılama ve uydu görüntüsü sınıflandırma alanında yapılmış çalışmalar kronolojik sıra içerisinde sunulmuş ve özetlenmiştir.

Çalışmanın ikinci bölümünde, temel bilgiler kapsamında uydu görüntüleri, uzaktan algılama ve sınıflandırma başlıklarına değinilmektedir.

Üçüncü bölümde, çalışmada incelenen veri setleri anlatılmaktadır. Buna ek olarak birleştirilen veri setinden ve birleştirme amacından bahsedilmektedir.

Çalışmanın dördüncü bölümünde, materyal ve metot kapsamında öznitelik çıkarımı, sınıflandırma metotları, derin öğrenme ve makine öğrenmesi tabanlı sınıflandırma, transfer öğrenmesi başlıklarına değinilmektedir.

Beşinci bölümde makine öğrenmesi ve derin öğrenme kapsamında yapılan analizlerden. Tüm veri setleri için analizler sonucunda elde edilen sınıflandırma başarılarından bahsedilmektedir.

Çalışmanın altıncı bölümünde çalışma kapsamında yapılan tüm analizler ve elde edilen sonuçlar değerlendirilmiş ve önerilerde bulunulmuştur.

2. KURAMSAL TEMELLER

2.1. Uydu Görüntüleri

Uydu araçlarından alınan görüntüler günümüzde hayatı kolaylaştırmak ve problemlerin çözümü amacıyla günümüzde astronomi, afet müdahalesi, çevresel izleme, coğrafi bilgilendirme sistemleri ve sınıflandırma gibi birçok alanda kullanılmaktadır. Uydu görüntülerinde en önemli kalite faktörlerinden bir tanesi kontrasttır. Kontrast iyileştirme bu alandaki görüntüleri işlemek konusunda oldukça önem arz etmektedir. Kontrast oluşumunun sebebi iki farklı yüzeyden yansıyan parlaklık farkından kaynaklanmaktadır. Kontrast bir nesnenin kendinden farklı nesnelerle renk ve parlaklık farkları ile belirlenmektedir [20], [21]. Uydu görüntülemesinde başlıca sorunlardan bir diğeri çözünürlük problemidir. Uydu görüntülerinden faydalanan bir sınıflandırma veya bir nesne tespiti yapılmak istendiğinde bu problem üzerinde iyileştirme yapılması gerekmektedir. Çözünürlük probleminin iyileştirilmesi amacıyla enterpolasyon yöntemleri sıklıkla kullanılmaktadır. Enterpolasyon teknikleri görüntüdeki piksel sayısını artırmaya yönelik işlemler gerçekleştirmektedir. Bu sayede çözünürlüğü artan görüntüde sınıflandırma ve nesne tespiti daha kolay bir şekilde yapılabilmektedir [22].

Uydu görüntülerinden bölge algılama işleminde algılanmak istenen bölgeler çok geniş alanlara sahip olduğu için geleneksel sınıflandırma yöntemleri her zaman istenilen başarıyı vermemektedir. Bu alanda derin öğrenme yöntemleri umut vaat eden algoritmalarlardır. Günümüzde ESA kullanılarak uydu görüntüleri algılamada başarılar elde edilmiştir [5].

2.1.1. Sayısal Görüntü

Uzaktan algılamada dünya yüzeyinden yayılan enerji bir araca monte edilmiş sensörler kullanılarak ölçülür. Enerji güneş ışığını yansıtma özelliğine sahiptir bundan dolayı kaydedilen görüntülerin dalga boyları genellikle insan görüşü dışındadır. Buna rağmen bir hava aracından dünya yüzeyi görünümüne birçok yönden benzer olmaktadır. Hava aracı üzerindeki sensörler yardımıyla alınan görüntünün en büyük avantajı sayısal formatta hazır olmasıdır. Veriler ayrık resim öğeleri ve piksellerden oluşmaktadır. Görüntülerin sayısal olarak alınabilmesinin en önemli avantajı daha anlaşılabilir bir biçime getirmek amacıyla bilgi çıkarma yada görsel nitelik geliştirme için işlenebilir olmasıdır [23].

Sayısal görüntüde bulunan bir piksel, görüntüdeki adres atanabilen en küçük öğedir. Başka bir deyişle bir görüntü veya resmin temsil edilebilen en küçük öğesidir. Her piksel gerçek görüntünün bir örneği olarak adlandırılabilir ve örnek sayısı (piksel sayısı) ne kadar fazla ise görüntü o derece doğru temsil edilebilmektedir. Piksellerin yoğunluk değerleri farklıdır. Renkli (RGB, Red Green Blue) görüntüleme sisteminde bir renk temel olarak kırmızı, yeşil, mavi veya camgöbeği, macenta, sarı ve siyah gibi farklı bileşen yoğunluklarıyla temsil edilmektedir [24].


2.1.2. Çözünürlük

Çözünürlük tanım olarak bir görüntünün keskinliğini ve netliğini ve sahip olduğu ayrıntıyı tanımlamak amacıyla kullanmakta olan bir ölçüdür. Yüksek çözünürlüğe sahip görüntüler daha fazla görüntü detayına sahip olmaktadır. Çözünürlük bir görüntüdeki inç başına piksel sayısı ile tanımlanmaktadır. Yüksek çözünürlük inç başına çok sayıda piksel anlamına gelmektedir buda görüntünün netliğini artırmaktadır [25]. Çözünürlük miktarı aynı zamanda görüntü işleme yöntemlerinde işlem yükü ile doğru orantılıdır ve çözünürlük miktarı arttıkça işlem yükü artmaktadır. Bu nedenle nesne tanıma ve algılama için yeterli ve doğru çözünürlüğü seçmek oldukça önem arz etmektedir [24].

2.1.3. Uydu görüntüleme sensörleri

Görüntüleme alanında kullanılan ilk uydular yörüngeye bakış açısına göre sabit bir görüş yönüne sahiplerdi. Panoramik kameraların kullanıma başlanması ile sadece bir taraftan diğerine tarama yapma mantığı ile görüş açısında genişletilme sağlanmıştır [26]. Uydu görüntüleme sensörleri temelinde 2 farklı tip olarak ayrılmaktadır. Bunlar optik sensörler ve mikrodalga sensörlerdir. Optik sensörler çalışma mantığı olarak dünya yüzeyi ve nesneler tarafından yansıtılan görünür ışık ışınlarının gücünü toplayarak kullanıcıya nesne ve ortamların doğasını anlama imkanı sunmaktadır. Bu sensörlerden karanlıkta ve kötü atmosfer koşullarında istenilen başarıda görüntüler elde edilememektedir. Kızılötesi optik sensörler ise çalışma mantığı olarak dünya yüzeyi ve nesnelerin yaydığı kızılötesi ışınları toplamaktadır. Bu sensörler karanlık koşullarda dahi yüzeydeki yüksek sıcaklıktaki cisimleri başarıyla seçebilme yeteneğine sahiptirler. Mikrodalga sensörler ise ışık ve atmosfer koşullarından tamamen bağımsız olarak çalışmaktadır ve yeryüzünden yansıyan mikrodalga sinyalleri toplamaktadırlar. Mikrodalga sensörler nehir dağ gibi birçok doğal ortam ve buz kalınlığı gibi bilgileri gözlemlemekte kullanıldığı gibi sıcaklıkları da gözlemlemektedir.

Sensörler tarafından görüntü yakalama işlemi Şekil 2.1.'de görüldüğü gibi aktif ve pasif modda sağlanabilmektedir [27].



Şekil 2.1. Aktif ve pasif sensör konsepti [27]

2.1.4. Uydu görüntülerinde çözünürlük

Uydu görüntülerindeki çözünürlük seviyesi görüntüdeki bir nesneyi veya özelliklerini tanıma ve ayırt etme başarı seviyesini doğrudan etkilemektedir. Daha öncede bahsettiğimiz üzere çözünürlük bir görüntüdeki ayrıntı ve bilgi miktarını temsil etmektedir. Uydu görüntülerine bakıldığında dört tür çözünürlük mevcuttur bunlar konumsal, spektral, zamansal ve radyometrik çözünürlüklerdir. Spektral çözünürlük anlam olarak spektral bantların sayısına karşılık gelmektedir. Ayrıca spektral çözünürlük ayırt etme yeteneği ile doğru orantılıdır yani bir görüntünün spektral çözünürlüğü ne kadar yüksek ise ayırt etme o kadar başarılı olmaktadır [27].

Konumsal çözünürlük anlam bakımından belirli bir anda tek bir sensör tarafından kapsanan en küçük alanı temsil etmektedir. Konumsal çözünürlük boyutu ve piksel boyutu ters orantılıdır. Bu sebeple uzamsal çözünürlük boyutu ne kadar büyükse küçük ayrıntıların yakalanma ihtimali o derece artmaktadır [27].

Zamansal çözünürlük bir görüntüdeki sahnenin tekrarlanmasına kadar olan zaman aralığını temsil etmektedir ve görüş açısı, yörünge gibi parametrelerle doğrudan bağlıdır.

Radyometrik çözünürlük ise sensör verilerinin gri seviyelerini temsil etmektedir. Radyometrik çözünürlüğün yüksek olması kullanıcıya yansımalarındaki küçük değişimlerin ayırt edilmesinde yardımcı olmaktadır [27], [28].


2.1.5. Uydu görüntülerinde bozulma

Uydu görüntülerinde bozulmaya sebep olan birçok etken mevcuttur. Bunlar başlıca çözünürlük, nesne pozisyonundaki düzensizlik, nesnelerin oryantasyonu, nesnelerin birbirini kapatması gibi çeşitli etkenler olabilmektedir. Geometrik bozulmalar ise temel olarak görüntülemeye en-boy değişikliği, algılayıcı özellikleri ve uydu veya nesnelerin hareketleri sebebiyle meydana gelmektedir. Buna ek olarak bozulmalar hedef hareketleri, konum değişikliği, sapma ve dönüş içeren uydu konumuna bağlı nedenler sonucunda da meydana gelebilmektedir [27].

2.2. Uzaktan Algılama

Uzaktan algılama tanım olarak gözlemciden uzakta bulunan bir nesne veya olayları algılama ve gözlemlene durumu olarak açıklanabilmektedir. Genellikle sabit veya hareketli bir ortamda oluşturulan görüntü ile dünya yüzeyini gözlemlene ve algılama tekniklerini barındırmaktadır. Uydu görüntüsü elde etme ve uzaktan algılama alanında bu amaçla kullanılan sensörler hava araçlarında kullanılarak görüntü verileri elde edilmektedir. Sensörler uzaktan algılama yaptıkları için nesne ve olaylarla yakın temasta bulunmamaktadır. Elektromanyetik radyasyon Şekil 2.2.'de gösterildiği gibi nesneler ve sensörler arasında bilgi iletimini sağlayan bir fiziksel taşıyıcı görevi görmektedir. Uzaktan algılama sistemlerinde çıktılar genel olarak bir sayısal görüntü biçiminde olmaktadır. Uzaktan algılama amaç olarak dünya yüzeyi ve atmosfer hakkında bilgi edinme alanında sıklıkla kullanılmaktadır [29].

Farklı nesneler malzeme özelliklerine, ışın gelme açısına, yüzey pürüzlülüğü gibi birçok farklı etkene bağlı olarak üzerlerine gelen elektromanyetik ışınlarla karşılık farklı miktarlarda enerji döndürmektedirler. Bu özellikleri sayesinde nesneler başarılı bir şekilde ayırt edilebilmektedir [30].



Şekil 2.2.Uzaktan algılama işlemi

2.2.1. Uzaktan algılama aşamaları

Uzaktan algılama işlemi belirli aşamalar sonucu meydana gelmektedir ve bu aşamalardan her biri başarılı sonuçlar elde etmek için önem arz etmektedir. Bu aşamaların ilki elektromanyetik radyasyon (EMR) emisyonudur. Emisyon güneş kaynaklı yada kendi kendine gerçekleşebilmektedir. Devamında enerjinin kaynaktan yeryüzüne iletilmesi ve saçılma gelmektedir. Bu aşamayı EMR'nin dünya yüzeyi ile etkileşimi yani yansıma ve emisyon takip etmektedir. Sonrasında enerji yüzeyden uzakta olan sensörlere aktarılmakta ve son olarak veri çıkışı sağlanmaktadır [30].

2.2.2. Uzaktan algılayıcı uzay platformları


1946 yılından öncesinde uzaktan algılama çoğunlukla uçaklar ve balonlar üzerinden sağlanmıştır. 1946 yılında V-2 roketleri ile uzaktan algılama amaçlı fotoğraflar çekilmiştir. Dünya üzerinde düzenli olarak yörünge gözlemi çalışmaları 1960 yılında çözünürlük olarak zayıf olan ilk meteorolojik uydu Tiros I'in fırlatılmasıyla sağlanmıştır. 1961 yılında ilk renkli görüntüleme işlemi MA-4 Mercury insansız uzay aracında otomatik kameralar tarafından elde edilmiştir. Devamında sırasıyla Mercury, Gemini, Apollo, Skylab projeleriyle görüntüleme işlemleri gerçekleştirildi. Apollo 9'da dünya üzerindeki kaynakların gözlemi amacıyla ilk kez multispektral görüntüler elde edilmiştir [31].

2.2.3. Dünya ve gezegen atmosferleri yoluyla iletim

Atmosfer uzaktan görüntüleme çalışmaları için altında bulunan yüzeyler gözlemlenmek istendiğinde spektral bölgelerde sınırlamaya neden olmaktadır. Bu durumun sebebi başlıca belirli spektral bölgelerde absorpsiyon veya saçılmaya neden olan atmosferik ve iyonosferik bileşenlerle dalga etkileşimleridir. Dünya iyonosferi yüzey ile etkileşimde veya yüzeyden uydula iletişimde 10MHz'in altındaki frekanslar için iletimi engellemektedir. 10MHz ve üstü frekanslarda mikrodalgaya kadar atmosfer şeffaftır. Mikrodalga bölgesinde ise su buharı ve oksijen kaynaklı bir dizi absorpsiyon bandı mevcuttur. Dünya atmosferinde görünür bir kızılötesi opaklık mevcuttur. Bu opaklık yüksek absorpsiyon katsayılarının su buharı ve karbondioksit ile ilişkili elektronik ve titreşim kaynaklı etkenlerin sebep olduğu bantlarda yüksektir [31].

2.2.4. Elektromanyetik Spektrum


Elektromanyetik Radyasyon (EMR) dalga hareketi olarak yayılan dinamik bir enerji biçimidir. Dalga boyu (λ), frekans (ν) ve hız (c) Şekil 2.3'de gözlendiği gibi bir dalganın karakterini belirleyen parametrelerdir.



Şekil 2.3. Dalga yapısı [30]

Elektromanyetik enerji ışık hızında sinüzoidal bir yapıda hareket etmektedir. Elektromanyetik enerjinin madde ile etkileşimi parçacık teorisi yardımıyla açıklık

kazanmaktadır. Bu teori EMR'nin foton veya kuantı adı verilen bir dizi birimden oluştuğunu savunmaktadır. Elektromanyetik spektrum Şekil 2.4'de görüldüğü gibi dalga boylarına göre birçok spektral bölgeye ayrılmaktadır [31].



Şekil 2.4. Elektromanyetik spektrum [31]


2.2.5. Atmosfer ile enerji etkileşimleri

Güneş bir radyasyon kaynağıdır ve uzaktan algılama amaçlı sensörlerin algıladığı güneşten yansıyan EMR, güneş ve dünya yüzeyi arası hareketinde iki kez atmosferden geçmektedir. Bu geçişlerden ilki dünya yüzeyine ulaşırken ikincisi ise dünya yüzeyinden yansıyarak uydu yada uzay araçlarındaki sensörlere ulaşırken gerçekleşmektedir. Güneşten gelen radyasyon ve dünya yüzeyinden yansıyan radyasyonun atmosferik bileşenler ile etkileşimler uzaktan algılama işlemine etki etmektedir. Bu olaylara “Atmosferik Etkiler” denmektedir. EMR taşıması ile dünya yüzeyinden yansıyan bilgiler atmosferden geçerken değişikliğe maruz kalmaktadır. EMR ve atmosfer etkileşimi incelendiğinde atmosfer hakkında önemli bilgiler elde edilebilmektedir [30].

2.2.6. Dünya yüzey özellikleri ile enerji etkileşimi

Güneş tarafından iletilen EMR, dünya yüzeyine ulaştığında Şekil 2.5'de görüldüğü gibi iki durum meydana gelebilir bunlardan ilki EMR yüzeye geldiğinde yüzey tarafından


yansıtılır, iletilir diğer durum ise EMR'nin yüzeye ulaştığında yüzey tarafından emilmesi ve yayılmasıdır. EMR etkileşim sonrasında belirli değişikliklere uğramaktadır. Bu değişimler başlıca büyüklük, yön, dalga boyu, polarizasyon ve faz özelliklerinde meydana gelmektedir. Meydana gelen değişiklikler sensörler tarafından algılanmakta ve hedef nesne hakkında bilgilere ulaşılmasını sağlamaktadır. Yorumlanan veriler hem uzamsal hem de spektral bilgi barındırmaktadır [30].



Şekil 2.5. Dünya yüzeyi ile enerji etkileşimi [30]

2.2.7. Nesnelerin Spektral Yansımaları

EMR hedefe çarptığında iletilebilir, soğurulabilir veya yansıtılabilir. Yansıyan güneş kaynaklı radyasyon miktarını ölçme işlemi dalga boyunun bir fonksiyonu olarak gerçekleştirilmektedir ve bu spektral yansıma olarak adlandırılmaktadır. Şekil 2.6'da su, toprak ve bitki örtüsünün spektral yansımaları görülmektedir. Su radyasyonla etkileşime geçtiğinde çoğunu emmektedir ve çok az miktarda yansıtmaktadır. Zemin yüzeyler spektral yansıma eğrilerini oldukça düzgün meydana getirmektedirler. Topraktaki nem miktarı radyasyon yansımalarını doğrudan etkilemektedir ve toprak ne kadar kuru ise o kadar büyük oranda yansıma gerçekleşmektedir. Yeşil bitkiler bulundurdıkları klorofil nedeniyle absorpsiyona neden olurlar ve yansımanın düşük miktarda gerçekleşmesine neden olurlar [23].



Şekil 2.6. Bazı nesnelerin spektral yansımaları [23]

2.3. Sınıflandırma

Sınıflandırma temel anlam olarak mevcut bilgiler öğrenilerek ve yorumlanarak belirli kararların veya tahminlerin yapıldığı ve verilerin özelliklerine göre sınıf etiketlerine ayrıldığı bir yöntemdir. Sınıflandırma görevi çok çeşitli alanlarda kullanılmaktadır. Örneğin bir hastanın hastalık teşhisi gibi birçok alanda sınıflandırma kullanılmaktadır [32].

2.3.1. Denetimli öğrenme

Denetimli öğrenme, önceden atanmış doğru etiketlendirme kapsamında veri grubundan örneklerin eğitilme işlemine denmektedir. Denetimli öğrenmede eğitim setindeki her veri için bir sınıf etiketi sağlanmaktadır.

2.3.2. Denetimsiz Öğrenme

Denetimsiz öğrenme veya kümelemede sınıflandırma işlemi ne kadar başarılı olursa olsun hedef verilerin gerçekte kullanılan etiketleri hakkında hiçbir ipucu yoktur. Başarılı sınıflandırmaya yol açan önemli özellikleri belirlemek oldukça zordur. Sistemde bir açık bir öğretici yoktur ve girdi modellerinin kümeleri veya gruplaşmaları oluşturulmaktadır.



3. VERİ SETİ

3.1. Giriş

Yapılan çalışmalarda uzaktan algılama ve uydu görüntüleri sınıflandırma alanında kullanıma uygun olan birçok veri seti incelenmiş ve en uygun iki tanesine karar verilmiştir. Bunlar EuroSAT veri seti ve AID veri setidir. Seçilen derin öğrenme ve makine öğrenmesi tabanlı sınıflandırma algoritmaları iki veri seti üzerinde ayrı ayrı uygulandığı gibi uygun koşullar sağlanarak birleştirilmiş yeni oluşturulan bir veri seti üzerinde de uygulanmıştır. Veri setlerini birleştirerek yeni bir veri seti oluşturmamızın temel amacı farklı uydu görüntülerine dayanıklı ve genelleme yeteneği yüksek bir algoritma geliştirmektir.

3.2. Örnek Alanları


Sınıflandırma amaçlı örnek alanları iki veri seti içinde birbiriyle uyumlu ve uydu görüntüsü temelli uzaktan algılama ve bölge sınıflandırması amacıyla kullanılabilir sınıf etiketleri içermektedir.

EuroSAT veri seti Şekil 3.1’de görüldüğü gibi endüstriyel yapılar, nehir, orman, deniz ve göl gibi sınıfların bulunduğu 10 sınıf etiketi içeren uydu görüntülerine sahip bir veri setidir [14].



Şekil 3.1. EuroSAT veri seti [14]

AID veri seti Şekil 3.2’de görüldüğü gibi havalimanı, nehir, çöl, endüstriyel alan benzeri 30 sınıf etiketine sahip uzaktan algılama ve sınıflandırmaya uygun uydu görüntüleri içeren bir veri setidir [8].



Şekil 3.2. AID veri seti [8]

3.3. Kullanılan Veri Setleri

Çalışmada kullanılan veriler uzaktan algılama ve uydu görüntülerinden bölge ve yapı sınıflandırılmasına uygunluğu dikkate alınarak EuroSAT ve AID veri setlerinden seçilmiştir.

3.3.1. EuroSAT veri seti

EuroSAT veri seti yapılar ve arazi ortamlarından oluşan 10 sınıf etiketine sahip bir veri setidir. Veri seti bünyesinde 27000 etiketli görüntü bulundurmaktadır. Veri seti coğrafi referansa sahip olmakla birlikte Dünya gözlem verilerine dayanmaktadır. Veri seti Sentinel-2 uydusundan alınan görüntüleri içermektedir. Veri setinden mevcut veriler RGB olarak verildiği gibi çoklu-spektral (MS, Multi-spektral) versiyonu da mevcuttur [14].

EuroSAT veri kümesi Sentinel-2 uydu takımıyıldızının verilerinin ücretsiz olarak gözlem uygulamaları amacıyla erişilebilir hale getirilmesi temelinde oluşturulmuştur. Veri her sınıfında 2000 ila 3000 arasında sınıf etiketine sahip görüntü barındırmaktadır. Görüntü yamalarının çözünürlükleri 64x64 piksel ölçüsüne sahiptir. Veri seti endüstriyel yapıları içerdiği gibi tarımsal arazilerde yıllık mahsul ve kalıcı mahsul (örneğin bağ ve zeytinlikler) gibi sınıflandırmalara da elverişlidir. Veri örnekleri manuel olarak birçok kez kontrol edilmiş ve yanlış etiketlerle birlikte kar buz gibi yanıltıcı etken içeren görüntüler elenerek kullanıma en uygun hale getirilmiştir [14].

3.3.2. AID veri seti

Uzaktan algılama ve uydu görüntüsü temelli sınıflandırmayı geliştirmek amacıyla Google Earth görüntülerinden veri toplayarak büyük ölçekli bir hava görüntüsü veri seti AID oluşturulmuştur. Veri seti bünyesinde arazi alanları ve yapısal alanları barındırmaktadır [8].

Veri seti Şekil.'de görüldüğü gibi 30 sınıf etiketinden oluşmaktadır. Veriler uzaktan algılama alanında uzman kişiler tarafından kontrol edilerek etiketlenmiştir. Sınıf etiketleri 220 ila 420 arasında etiketlenmiş görüntü içermektedir. Veri seti toplamda 30 sınıf etiketi için 10000 görüntüden oluşmaktadır ve görüntülerin çözünürlükleri 600x600 piksel olacak şekilde sabitlenmiştir [8].

Google Earth görüntüleri birçok sensör tarafından toplandığı için AID veri seti aslında çok kaynaklı bir veri setidir. Veri setinde Çin, Almanya, Amerika Birleşik Devletleri, İngiltere vb. birçok farklı ülkeden farklı zamanlarda örnekler bulunmaktadır. Zaman ve mevsim şartları verilerin çeşitliliğini artırmaktadır [8].

3.3.3. Veri setlerinin birleştirilmesi

Çalışmada veri kümeler ayrı ayrı incelendiği gibi AID ve EuroSAT iki veri kümesi uygun şekilde birleştirilerek sınıflandırma algoritmaları birleşmiş veri kümesi üzerinde de

test edilmiştir. Bu iki veri kümesinin birleştirilmesinin temel nedenlerinden bir tanesi veri kümelerinin uydu görüntüsü yönünden en kapsamlı veri kümelerinden olmaları ve sınıf etiketi olarak sınıflandırma açısından uyumlu olmalarıdır. Veri kümelerini birleştirmenin temel amacı sınıf etiketi sayısını artırarak yeni oluşturulmuş veri kümesi üzerinde sınıflandırma başarısının nasıl olacağını gözlemlemektir.

İki veri kümesi birleştirilirken sınıf etiketi başına düşen görüntü sayısı dikkate alınmıştır. AID veri seti 30 sınıfa sahip ve sınıf başına 220 ila 420 arası görüntü bulundururken EuroSAT veri seti 10 sınıfa sahip ve sınıf başına 2000 ila 3000 görüntü bulundurmaktadır. Bu iki veri setini birleştirirken farklı olan sınıflar için EuroSAT veri kümesinden 2000 ila 3000 görüntü alınması durumunda sınıf etiketlerindeki görüntü örneği sayısında dengesizlik olacağı için farklı olan sınıf etiketi başına 300 görüntü alınarak yeni veri kümesi oluşturulmuştur. Veri seti birleştirmede 300 seçilmesinin sebebi AID veri setinde sınıf etiketi başına yaklaşık 300 görüntü olmasından kaynaklıdır.

Birleşme sonrasında yeni oluşturulmuş veri seti 37 sınıfa sahip ve 12100 adet etiketlenmiş görüntüye sahiptir.

4. MATERYAL VE METOT

4.1. Derin Öğrenme

Derin öğrenme öznitelik çıkarma ve bu öznitelikleri hiyerarşik olarak öğrenme amacıyla kullanılan çok katmanlı yapay sinir ağı temelli bir teoridir. Derin öğrenme metotlarının görüntü tanıma ve işleme problemlerinde oldukça başarılı oldukları gözlenmektedir. Bunun başlıca sebeplerinden bir tanesi yapısının görsel kortekse oldukça benzer olmasıdır. Yapılar bünyesinde evrimsel katmanları, havuzlama katmanlarını ve doğrusal olmayan katmanları barındırmaktadır [33], [34]. Derin sinir ağları (DSA) yapılarında her katmanda belirli sayıda nöronlar bulundurmaktadır ve her katman kendinden bir önceki katmanın çıkışını girdi olarak almakta ve kendi çıkışını hesaplamaktadır. Eğitim sırasında DSA yapısına belirli bir veri seti girdi olarak verilir ve ilk olarak ağırlıklar rastgele olarak ağ yapısı başlatılır. Ancak başka bir yöntem ise daha önceden belirli bir veri kümesi üzerinde eğitilmiş bir ağın üzerinde hedef veri setine uygun biçimde ince ayar yaparak kullanmaktır. Bu yöntem günümüzde transfer öğrenmesi olarak bilinmektedir [35].

4.2. Öznitelik Çıkarma

Öznitelik çıkarma seçilen veri kümesinden daha önemli yeni öznitelikler çıkarma ve veri kümesini işlemek için gerekli kaynak miktarını azaltma alanında oldukça faydalıdır. Öznitelik çıkarma işleminde, daha önemli öznitelikler oluşturmak için mevcut öznitelikler dönüşümleri üretilmektedir. İşlemler sonucunda mevcut girdi öznitelik kümesinden çıkarılan öznitelikler daha küçük boyutlu bir öznitelik vektörü oluşturulmasına yaramaktadır. Boyut küçültme işlemleri, öznitelikler arasındaki ilişkiyi korumayı, bilgi kaybını önlemeyi ve gerçek veri yapısını kapsamayı amaçlamaktadır. Öznitelik çıkarımı sınıflandırma başarısında önemli bir rol oynamaktadır [36]. Karmaşıklığı azaltmak ve öznitelik uzayındaki her değişkeni orijinal girdi değişkenleriyle ilişkili bir kombinasyon olarak temsil etmek için öznitelik çıkarma kullanılmaktadır. En popüler yöntemlerden bir tanesi Karl tarafından ortaya sunulan temel Bileşen Analizidir. PCA yöntemi bir dizi fazlalık veya gürültü içeren veriden en anlamlı bilgileri çıkaran parametrik olmayan bir dönüşümdür [37].


Öznitelik çıkarma yöntemleriyle çıkarılan öznitelikler daha sonrasında verileri etiketlemek amacıyla bir sınıflandırıcıda kullanılmaktadır. Öznitelikler görüntüdeki bir nesne veya görüntünün tamamını tanımlamak için kullanılabilir. Bu nedenle öznitelik

çıkarmı ve uygun öznitelik vektörü oluşturulması sınıflandırmada önemli rol oynamaktadır [38].

Öznitelik seçimi ile karşılaştırdığımızda öznitelik çıkarma yüksek sayıda özniteliği daha düşük ve anlamlı bir dizi özniteliğe indirgemektedir. Bu sayede değişken sayısı ve işlem yükü azalmaktadır. Amaç yüksek boyuta sahip veri problemini çözerek düşük boyutlu temsil kümeleri oluşturmaktır. Öznitelik seçimi yerine öznitelik çıkarmı kullanarak daha az veri bilgi ve daha başarılı ayırt etme sağlanabilmektedir [36].

4.3. Transfer Öğrenmesi Tabanlı Sınıflandırma

Evrişimsel sinir ağları son dönemde makine öğrenmesi alanında büyük ilerlemeler kat ederek tamamen egemen olmuştur. ESA yapı olarak girdi katmanı, çıktı katmanı ve birçok gizli katmandan oluşmaktadır. ESA yapısında gizli katmanlar evrişimsel katmanlar, havuzlama katmanları, tam bağlı katmanlar ve ReLU katmanından oluşmaktadır. Genel bir ESA örneği Şekil 4.1’de gösterilmektedir [39].



Şekil 4.1. Esa mimarisi [39]

ESA yapıları görüntü tanıma ve sınıflandırma amacıyla tasarlanmış bir sinir ağı kategorisidir. Günümüze kadar yüz tanıma, nesne tanıma, görüntülerden hastalık tespitleri gibi birçok çeşitli alanda başarıyla uygulanmıştır. ESA mimarisi, dünyayı görsel olarak algılamak üzerine insan beyni ile benzer mantıkta çalışmak için tasarlanmıştır [40].

Lineer cebir ESA mimarisinin çalışma prensibinin temelini oluşturur. Matris vektör çarpımı, veri ağırlıklarının taşınmasının temelini oluşturmaktadır. ESA yapısındaki her katman bir görüntünün farklı özelliklerini öğrenmek için tasarlanmıştır. Bu nedenle öznitelik çıkarmı açısından çeşitliliğe sebep olmaktadır. Evrişimsel katmanlar ESA yapısında amaç olarak girdi görüntüsünde pikseller arası ilişkileri koruyarak öznitelik çıkarmını

sağlamaktadır. Havuzlama katmanı amaç olarak görüntü yığını küçültmeyi amaçlamaktadır ve bu katmanda öznitelik haritalarının boyutları küçültülmektedir. Normalleştirme katmanı olan ReLU katmanı yapı içindeki negatif değerlerin 0'a değiştirilmesini sağlamaktadır. Ağın son katmanı olan tam bağlı katman ESA yapısında sınıflandırma görevini üstlenmektedir. Bu katmana gelindiğinde sınıflandırılma gerçekleştirilmekte ve örnek veriler etiketlenilmektedir [39], [40].

Transfer öğrenmesi mantık olarak problemleri daha hızlı ve daha başarılı bir şekilde çözebilmek için daha önceden öğrenilmiş bilgi ve çözümleri başka bir örnek kümesinin çözümünde uygulamaya dayanmaktadır. Transfer öğrenmesi eğitimde ve testte kullanılan alan, görev ve dağılımların farklılık göstermesine izin vermektedir [41]. Bir başka deyişle transfer öğrenmesi bir ağın temel bir kaynak veri seti ve görev üzerinde eğitilmesi, sonrasında öğrenilen özelliklerin başka bir ağa hedef veri seti eğitilmek için aktarılmasıdır [42].


Derin öğrenmenin ana avantajlarından bir tanesi öğrenme amaçlı çok miktarda veriden faydalanma yeteneğinin olmasıdır. Uygulamalarda bir ESA ağını eğitmek için büyük boyutta veri kümelerine ihtiyaç duyulmaktadır. Bu bakış açısında zorluk fazla verinin mevcut olmadığı durumlarda başarılı bir öğrenmeyi sağlamaktır. Transfer öğrenmesi bu problem üzerine yoğunlaşarak ortaya çıkmış bir tekniktir. Transfer öğrenmesi böyle durumlar için çok uygun olmakla birlikte sınıflandırma performansını artıracak öznitelikler çıkarımını sağlamaktadır [43], [44].

Transfer öğrenmesi uygulama alanında dikkat edilmesi gereken iki ana bölüme ayrılmaktadır. Bunlar önceden eğitilmiş modelin seçimi, problem boyutu ve benzerliğidir. Önceden eğitilmiş bir model seçimi problemle ilgili olarak problem dikkate alınarak yapılmalıdır. Hedef veri seti ve seçilen ağın kaynak veri kümesi benzer ise ağın aşırı uydurma şansı düşük olmaktadır [44].

4.3.1. DenseNet-201

DenseNet-201 derin öğrenme ağı 201 adet katman içeren bir yapıdadır. Bu yapıda Şekil 4.2'de görüldüğü gibi her katman doğrudan diğer tüm katmanlarla bağlantılıdır. Başka bir deyişle bir katmana kendisinden önceki katman ile birlikte arkasında kalan bütün katmanlardan bilgi girişi bulunmaktadır [45]. DenseNet-201 ağının katmanlar arasındaki direk bağlantıları sayesinde bir özniteliği tekrardan kullanmaya teşvik etme avantajı vardır [46]. Buna ek olarak, katmanlar arasındaki bu bağlantılar nedeniyle yüksek sistem gereksinimine ihtiyaç duyulması ağın dezavantajıdır. Ağ yapısında bulunan her katmanın

girişi aynı yapıda bulunan önceki bütün katmanların öz nitelik haritalarının birleşimidir [47]. Bu yapı öz nitelik çeşitliliğini arttırmaktadır. DenseNet-201 ağının bu üstünlüklerinden dolayı uydu görüntülerinin sınıflandırılması çalışmasında başarılı olduğu görülmektedir.




Şekil 4.2. DenseNet-201 ağ yapısı [45]

4.3.2. AlexNet

AlexNet 60 milyon parametre ve 650 bin nöron içeren Şekil 4.3’de görüldüğü gibi 7 katmana sahip bir derin öğrenme ağıdır [48]. AlexNet derin öğrenme ağı yapısında 3 evrişim katmanı ve 2 tam bağlantı katmanı bulundurmaktadır [49]. AlexNet derin öğrenme ağı görüntü sınıflandırma problemlerinde sıklıkla kullanılmaktadır. AlexNet aktivasyon fonksiyonu olarak genellikle ReLU aktivasyon fonksiyonu kullanmaktadır ve bırakma(dropout) fonksiyonunu yapısında bulundurmaktadır. Bırakma fonksiyonu sayesinde her tekrarlamada nöronların yalnızca seçilmiş miktarı eğitilmektedir. Bırakma fonksiyonu bir nöronu diğerleriyle etkileşime sokmaya zorlar ve nöronlar arası ortak adaptasyonda azalmaya sebep olarak genelleme yeteneğini artırmaktadır [48]. Öz nitelik


çıkarımı kısmında evrimsel katmanlar ve havuzlama katmanları kullanıldığı gibi sınıflandırma kısmında ise tam bağlantılı katmanlar ile sınıflandırma yapılmaktadır [50].




Şekil 4.3. AlexNet ağ yapısı [49]

4.3.3. GoogLeNet

GoogLeNet derin öğrenme ağı 2014 yılında hesaplama verimliliği ve pratiklik göz önünde bulundurularak tasarlanmıştır [51]. Ağ yapısının en büyük avantajı sınırlı miktarda hesaplama kaynağına sahip ve düşük sistem özelliklerine sahip olanlar rahatlıkla kullanabilmektedir [52]. GoogLeNet ağ yapısı Şekil 4.4’de görüldüğü gibi 22 adet parametrelili katmandan oluşmaktadır. Havuzlama katmanlarıyla birlikte 27 katmanlı bir derin öğrenme ağıdır [53]. GoogLeNet mimarisinde 9 adet başlangıç modülü vardır ve bu 9 başlangıç modülü 3lü olarak 3 adet gruba ayrılmış durumdadır. Bu 9 modül gradyan kaybolması sorunu ve aşırı uydurma sorununu ortadan kaldırmak için eklenmektedir. Ağ yapısında başlangıç modülü karmaşıklığı önlemeye yardımcı olan Şekil 4.5’de görüldüğü gibi küçük boyutlu 1x1 , 3x3 ve 5x5 gibi birkaç evrimsel katmandan oluşmaktadır [54][55]. GoogLeNet ağ yapısı hesaplama karmaşıklığında kontrolsüz bir artışa neden olmadan her katmanda birim sayısını artırmaya izin vermektedir [53].



Şekil 4.4. GoogLeNet ağ yapısı [54]




Şekil 4.5. Başlangıç modülü [54]

4.3.4. ResNet

ResNet derin öğrenme ağı 2015 yılında tanıtılmış ve bilgisayar görüşü alanında birçok başarıya imza atmış bir derin öğrenme ağıdır. Yapısı incelendiğinde Şekil 4.6’da görüldüğü gibi belirli katmanların üzerinden atlayan atlama bağlantılarına ve kısa yollarına sahiptir [56]. ESA’nın temel problemi artan derinlikle doğru orantılı olarak gradyanların kaybolması ve bozulma problemlerinin meydana gelmesidir. ResNet ağ yapısı 150 katmanın üstündeki ağlarda dahi atlamalı bağlantı yapıları sayesinde derinliğe bağlı meydana gelen problemleri çözmektedir [57], [58]. ESA ağ yapılarında ağların derinliği arttıkça ağı eğitmekte bir o derece zorlaşmaktadır. ResNet derin öğrenme ağı yapısı sayesinde bu sorunu ortadan kaldırmaktadır. ResNet ile ağı derinliği artsa da ağı eğitmek o ölçüde artmamaktadır ve bu sayede derin ağ yapılarına sahip yapılarda kolaylıkla eğitilebilmektedir [59].


ResNet derin öğrenme ağı her modülünde 4 adet evrimsel katman içeren bir dizi modülden oluşmaktadır. Modüllerde farklı sayıda katman ve ResNet yapısında bulunan artık katmanlardan kullanarak birçok farklı ResNet modeli oluşturulmaktadır. Bu modüller başlıca ResNet-18 (18 katmanlı) , ResNet-50 (50 katmanlı) , ResNet-152 (152 katmanlı) olarak bilinmektedir [58].



Şekil 4.6. ResNet-18 ağ yapısı [58]

4.3.5. MobileNetV2


MobileNetV2 2018 yılında tanıtılmış ve derin öğrenme alanında yaygın olarak kullanılan ESA yapılarından bir tanesidir. Yapısında Şekil 4.7’de görüldüğü gibi 154 katman ve 3.4 milyon parametre mevcuttur. Bu ağ yapısında ters çevrilmiş artık ve doğrusal darboğaz bulunmaktadır. Bu nedenle ResNet ağının kalıntı yapısından da yararlanmaktadır [60]–[62]. Ağ yapısından 2x2 maksimum havuzlama katmanı tarafından takip edilen 3x3 ve 1x1 evrişimsel katmanlar ve darboğaz işlemleri bulunmaktadır. Bu çok katmanlı blok yapı birden çok kez tekrar edilmektedir ve bunları sınıflandırma amaçlı tam bağlı katman takip etmektedir [63]. Evrişim katmanları veri kümelerine tekrar tekrar uygulanan filtreleri hesaplayarak öznitelik haritalarını oluşturmaktadır ve bu sayede eğitim başarısının artırılması hedeflenmektedir. MobileNetV2 mimarisi bellek gereksinimi ve yürütme hızını optimize ederek çalışan bir mimari yapıya sahiptir. Bu yapı derinlemesine ayarlanabilir bir evrişimsel bir yapı sunmaktadır [64].



Şekil 4.7. MobileNetV2 ağ yapısı [65]

4.3.6. VGG-16

ILSRVC yarışmasında ikinci olan Görsel Geometri Grubu (Visual Geometry Group, VGG) çalışmasının katkısı; ağın derinliğinin daha iyi tanıma ve sınıflandırma yapma konusunda önemli bir etken olduğunu göstermesidir [49]. VGG-16 ağ yapısı Şekil 4.8’de görüldüğü gibi formatında 13 evrişimsel katman , 2 tam bağlantılı katman ve 1 adet softmax katman olmak üzere toplamda 16 katmandan oluşmaktadır [66][67]. Ağ yapısında işlem kolaylığı için yalnızca 3x3 evrişimsel katmanlar kullanılmaktadır [68]. VGG-16 ağ yapısı 16 katmana sahip olsa da VGG-11 (11 katmanlı) ve VGG-19 (19 katmanlı) olarak farklı katmanlarda yapıları da mevcuttur [49]. Birinci ve ikinci evrişim katmanları 64 özniteliğe sahip çekirdek filtreden oluşmaktadır. Üçüncü ve dördüncü evrişimsel katmanlar 128 özniteliğe sahip çekirdek filtrelerinden oluşmaktadır. Beş, altı ve yedinci evrişimsel katmanları 256 özniteliğe sahip çekirdeklerden oluşmaktadır. Sekizinci evrişimsel katmandan on üçüncü evrişimsel katmana kadar olan kısım 512 özniteliğe sahip çekirdeklere sahiptir ve giriş görüntüsü bu katmanlardan geçtikten sonra maksimum havuzlama katmanına iletilmektedir. Son üç katman ise sınıflandırma amaçlı olup iki tane tam bağlı katman ve softmax katmanından oluşmaktadır [68].



Şekil 4.8. VGG-16 ağ yapısı [68]

4.4. Makine Öğrenmesi Tabanlı Sınıflandırma

İnsanlar var oluşlarından itibaren problemlere çözüm amaçlı farklı metotlar ve araçlar kullanmaktadır. Bu gereksinim zaman içinde makinelerin icadına yol açmıştır. Bu makinelerin amaçları insanların problemlere çözüm oluşturmada kolaylık sağlamaktır. Makine öğrenmesi de bu metotlardan bir tanesidir [69].


Makine öğrenmesi , yapay zekanın teknolojisinin bir alt dalıdır ve verilerin özelliklerini keşfetmek, insanlar tarafından anlaşılabilir modellere uydurmak amacıyla örüntü tanımadan geliştirilmiştir [70]. Makine öğrenmesi temelde ortamdan öğrenerek insan zekasını taklit etmek ve makinelere verileri verimli bir şekilde öğretmek amacıyla tasarlanmıştır. Bu nedenle problemlere bakış açısında çözümü kolaylaştıran bu yöntemler örüntü tanıma , bilgisayar görüşü, mühendislik, biyomedikal, finans gibi çeşitli alanlarda başarıyla kullanılmaktadır [69], [71].

Makine öğrenmesi problemleri çözmek için çeşitli algoritmalarından faydalanmaktadır. Bir algoritmanın çeşitli problemlerin hepsinde en başarılı olduğu söylenememektedir. Problemlere ve veri setlerine göre başarılı algoritma değişmektedir. Kullanılan algoritma, problem türü , değişken sayısı , modelin türü gibi belirli parametrelere bağlı olarak değişiklik göstermektedir [69]. Makine öğrenmesinin temelinde denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme, pekiştirmeli öğrenme olarak 4 çeşit öğrenme yöntemi bulunmaktadır.

4.4.1. Karar Ağaçları

Karar ağaçları tanım olarak bir özellik kümesi tarafından tanımlanan bir nesne ya da durumu girdi olarak alan ve evet hayır kararı veren bir yapıya sahiptir. Bu nedenle mantık fonksiyonlarını temsil ederler ve evet/hayır yanıtları hiyerarşik bir yapı içinde bulunarak ağaç ve dallarını meydana getirerek karar ağaçlarının şeklini oluşturmaktadır [72]. Karar ağaçları yapısındaki her dalda (ya da düğümde) tanımlı olan belirli testler çerçevesinde veri kümesini yinelemeli olarak daha küçük alt kümelere ayıran ve sonunda sınıflandırma işlemi yapan bir sınıflandırma yöntemidir. Algoritma yapı olarak Şekil 4.9’da gösterildiği gibi tüm verilerin bulunduğu bir kök düğümü , bir dizi dal düğüm ve bir dizi yaprak düğümünden oluşur [73]. Karar verilecek özellik sayısına göre dal düğümleri ve ağaç yapısı genişlemektedir. Ağacın yapısında veri seti alınan kararlar doğrultusunda alt bölümlere ayrılarak yaprak düğümlerine ulaşır. Yaprak düğümlerine farklı sınıf etiketleri atandığından alınan kararlar doğrultusunda veriler ulaştıkları yaprak düğümlerinde sınıflandırılmış

olmaktadır [74]. Karar ağaçlarının bazı avantajları vardır. Belirgin özelliklerinden birisi parametrik değildir ve girdi verilerinin dağılımında varsayım gerektirmemektedirler. Öznitelikler ve sınıflar arasında doğrusal olmayan bir ilişki vardır. Eksik değerlere izin verir ve hem sayısal hem de kategorik verileri sınıflandırabilmektedir.




Şekil 4.9. Karar ağacı yapısı [73]

4.4.2. Destek vektör makineleri

Destek vektör makineleri ilk olarak sınıflandırma için geliştirilmiştir ve devamında eğri uydurma, referans öğrenme uygulamaları için genişletilmiştir. DVM yapısında ikili sınıflandırma mevcuttur; bu öğrenilen fonksiyonun çıktısının pozitif ya da negatif olduğu bir ikili sınıflandırmadır. Çok sınıflı bir sınıflandırma yapılmak istendiğinde birden çok ikili sınıflandırıcı birleştirilerek gerçekleştirilmektedir [75][76]. DVM istatistiksel bir öğrenme teorisine dayanmaktadır ve geniş boyutlu bir uzayda en uygun destek vektörünü bulmaya çalışır [77]. Temel olarak DVM sınıf dağılımlarının kenarında kalan örnekleri ve destek vektörlerini dikkate alarak sınıflar arasında optimal bir ayırma yapabilmek için hiperdüzlem uydurma kavramına dayanan bir sınıflandırma yapmaktadır. Bu sayede küçük veri setlerinde dahi başarılı bir sınıflandırma imkanı sunmaktadır. DVM ile sınıflandırmayı özetlemenin en iyi yolu iki sınıfın q boyutlu uzayda doğrusal olarak ayrılabilirdiği durumdur. Bu işlem için öznitelik uzayında sınıfları ayıran karar sınırları veya hiperdüzlemler gerekmektedir. Sınıfları ayırmak için Şekil.'de görüldüğü gibi birçok hiperdüzlem mevcut olabilir ancak en

yüksek marja sahip optimum olan bir hiperdüzlem seçilmektedir. Bu hiperdüzlemler üzerindeki eğitim verileri destek vektörleri olarak adlandırılmaktadır [76].



Şekil 4.10. İki boyutlu uzayda hiperdüzlemler


4.4.3. K-en yakın komşuluk algoritması

KNN sınıflandırma alanında çok yaygın olarak kullanılmakta olan bir metottur. En büyük avantajlarından bir tanesi kolay yorumlama özelliği ve düşük hesaplama süresi özelliklerine sahip olmasıdır. KNN yöntemi en yakın komşuluk kurallarına bakarak genelleme yapan bir yorumlama algoritmasıdır [78].

En yakın komşu veya komşular ile karşılaştırma yaparak karar vermektedir. Karar verme aşamasında karşılaştırılacak komşu sayısını k parametresi belirlemektedir ve bu parametreye göre genelleme farklılık göstermektedir. K parametresinin doğru ve tek sayı seçilmesi bu algoritmada çok önemlidir. K parametresi arttıkça algoritmanın daha çok bilgi almasına ve daha fazla sayıda komşuluk ile karşılaştırma yapmasına sebep olmaktadır [79]. Seçilen K parametresine bağlı olarak bir veri örneği geldiğinde en yakın K adet komşusunun tespiti Eşitlik 4.1’de gösterilen Öklid denklemi ile mesafeler hesaplanarak sağlanmaktadır.

$$D(x, x_i) = \sqrt{\sum_{i=1}^k (x - x_i)^2} \quad (4.1)$$

Şekil 4.11’de görüldüğü gibi birden fazla sınıf bulunmaktadır ve yeni gelen veri örneğinin etiketini bulmak için k parametresine bakılır k parametresi kaç olarak seçilmişse o sayıda en yakın komşunun tespiti için veri kümesindeki örnekler ile sınıflandırılacak veri arasındaki Öklid mesafesine bakılmaktadır. En yakın komşular sayı olarak hangi sınıf etiketinde çoğunlukta ise sınıflandırılacak veri o sınıf etiketi ile etiketlenilmektedir [80].



Şekil 4.11. KNN sınıflandırıcı örneği [80]

4.4.4. Naive Bayes

Naive Bayes (NB) sınıflandırma algoritması metin sınıflandırma alanında en başarılı yöntemlerden biridir [81]. NB algoritması, öğrenme anlamında oldukça pratik bir metottur. NB algoritması, bütün x örneklerinin bir birleşim ile tanımladığı ve $f(x)$ hedef fonksiyonunun sonlu bir C kümesinden değer alabildiği problemler için uygulanmaktadır [82]. NB sınıflandırıcısı, belirli bir öznelik değerinin mevcut farklı öznelik değerlerinin hepsi ile farklı olduğunu varsaymaktadır [83]. NB algoritması eşitlik 4.2’de gösterildiği gibi her ilişki için koşullu bir olasılık türetmek amacıyla bağımsız değişken ve bağımlı değişkenler arasındaki ilişkiyi kullanmaktadır.

$$P(H|X) = P(X|H) P(H)/P(X) \quad (4.2)$$

Eşitlik 4.2’de gördüğümüz gibi x veri kaydı olduğunda. H, bir C sınıfına ait X veri kaydını temsil eden hipotez olmaktadır. Sınıflandırma için x dikkate alındığında amaç $P(H|X)$ ’i yani H hipotezinin olasılığını bulmaktır. Denklem.’de $P(H)$ önceki olasılığı temsil etmektedir [84]. Naive Bayes algoritması bahsedilen olasılık teoremlerinden faydalananarak sınıflandırmaya yardımcı olmaktadır.

4.4.5. Topluluk Metotları

Topluluk (Ensemble) yöntemleri, Hansen , Salamon ve Schapire tarafından çalışmalar vesilesiyle 1990 yıllarının başlarında aktif bir öğrenme sistemi haline geldi. Yapay Sinir Ağları (YSA) veya Karar Ağaçları gibi kararsız sınıflandırıcılarda iyileştirme amacıyla düzenleme ve gürültü ekleme gibi yöntemler denenmektedir. Topluluk metotları bu iyileştirmelerden farklı olarak birçok zayıf sınıflandırıcının topluluklar olarak birleştirilmesidir. En sık kullanılan yöntemler torbalama(bagging) ve artırmadır(Boosting) [85], [86]. Topluluk sınıflandırmasında her biri bağımsız karar verme özelliğine sahip birçok temel sınıflandırıcı birleşmiş halde mevcuttur. Birden fazla sınıflandırıcının tahmin yeteneği tek sınıflandırıcıdan üstündür mantığından yola çıkarak hareket edilmektedir. Bir sınıflandırıcı çeşitli problemlerle karşılaştığında farklı bir sınıflandırıcı çeşitlilik sağlayabilmektedir. Karar verme sürecinde basit çoğunluk oyu ile karar verilmekte ve sonuç nihai topluluk sonucu olarak kabul edilmektedir [87], [88].

Torbalama yönteminde veri kümesinden rastgele alt kümeler oluşturulmakta ve bu alt kümeler farklı temel sınıflandırıcılar oluşturmak için kullanılmaktadır. Artırma yönteminde ise veri setindeki zor örneklerin eğitim için kullanılma olasılığı daha yüksektir ve kolay örneklerin kullanılma şansı düşüktür. Bunun sonucunda çoğu temel sınıflandırıcı eğitim başarısını artıracak olan zor örneklerle odaklanmaktadır [89].

4.5. Sınıflandırma Başarısının Değerlendirilmesi

Sınıflandırma algoritmalarında başarı kriterinin değerlendirilmesi söz konusu olduğunda karışıklık matrisi kullanılmaktadır. Karışıklık matrisi bünyesinde Tablo 4.1’de gösterildiği gibi gerçek ve tahmin edilen sınıflandırma sonuçlarını bulundurmaktadır [90].

Tablo 4.1.Karışıklık matrisi


		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Sınıflandırma algoritması bir örnek ile karşı karşıya geldiğinde olası 4 sonuç ihtimali vardır. Örnek pozitif ve sınıflandırma sonucu etiketi pozitifse gerçek pozitif olmakta, örnek pozitif sınıflandırma sonucu negatif olduğu durumda yanlış negatif olmaktadır. Örnek negatif olduğunda ise sınıflandırma sonucu pozitif olduğunda yanlış pozitif ve sınıflandırma sonucu negatif olduğunda doğru negatif olmaktadır. Sınıflandırma performansını belirleme aşamasında doğruluk önemli rol oynamaktadır. Doğruluk tüm doğru değerlerin toplamının (DP, DN) doğru ve yanlış tüm değerlerin toplamına oranlanmasıyla hesaplanmaktadır. Doğruluk eşitlik (4.3)'de verilmiştir [91].

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (4.3)$$

5. DENEYSEL ÇALIŞMA VE SONUÇLAR

Bu çalışmada EuroSAT ve AID olmak üzere iki farklı veri seti ve ikisinin birleşiminden oluşan bir birleşik veri seti olmak üzere toplamda üç farklı veri seti üzerinde deneysel çalışmalar yapılmış ve sınıflandırma sonuçlarının analiz edilmesi hedeflenmiştir. Sınıflandırma için veri setlerinde bulunan RGB görüntülerden faydalanılmıştır. Deneysel çalışmalar Şekil 5.1’de görüldüğü gibi derin öğrenme ve makine öğrenmesi tabanlı sınıflandırıcılardan faydalanılarak gerçekleştirilmiştir. EuroSAT ve AID veri setlerine derin öğrenme tabanlı sınıflandırma işlemi uygulanmıştır. Birleşik veri setine ise hem derin öğrenme tabanlı hem de makine öğrenmesi tabanlı sınıflandırma işlemleri uygulanmıştır. Bu işlemdeki amaç makine öğrenmesi tabanlı sınıflandırma ve derin öğrenme tabanlı sınıflandırmanın birleşik veri setimiz üzerindeki başarılarının kıyaslanmasıdır. Makine öğrenmesi tabanlı sınıflandırma işlemlerinde veri setlerinde öznitelik çıkarımı açısından en başarılı ağ seçilerek derin öğrenme yöntemleri ile öznitelik çıkarımı yapılmış ve sonrasında makine öğrenmesi tabanlı sınıflandırıcılar kullanılarak sınıflandırma analizleri gerçekleştirilmiştir. Öznitelik çıkarımı aşamasında DenseNet-201, ResNet-18 ve AlexNet olmak üzere üç farklı derin öğrenme ağı kullanılmıştır. Çalışmamızda sınıflandırma çalışmaları yapılırken veri setimizin %80’lik kısmı eğitim için %20’lik kısmı doğrulama için seçilmiştir. Buna ek olarak sınıflandırma çalışmalarımızda maksimum verimliliği elde etmek amacıyla iki farklı optimizasyon algoritması test edilmiştir. Bunlar SGDM ve ADAM optimizasyon algoritmalarıdır. Yapılan çalışmalarda uydu görüntüsü ve uzaktan algılama veri setlerinde SGDM optimizasyon algoritmasının sınıflandırma çalışmalarında daha başarılı olduğu analiz edilmiş ve çalışmalarımızda SGDM optimizasyon algoritması kullanılmıştır. İki farklı veri setinde analizler yapıldıktan sonra veri setleri birleştirilerek sınıf sayısı ve görüntü miktarı olarak zengin bir veri seti oluşturulmuş ve bu veri setinde analizlerin sınıf sayısındaki artışa göre değişimleri incelenmiştir. Bu tez kapsamında yapılan tüm çalışmalar MATLAB 2021a ortamında gerçekleştirilmiştir. Analizlerimiz AMD Ryzen 5 3500 6-core 3.59 GHz işlemci, 16 GB bellek, NVIDIA GeForce RTX2060 GPU özelliklerine sahip sistem ile yapılmıştır.




Şekil 5.1. Uydu görüntülerinin sınıflandırma blok şeması

5.1. EuroSAT Veri Seti İçin Sınıflandırma Sonuçları

EuroSAT veri seti farklı ortamlardan oluşan 10 sınıf etiketi ve 27000 etiketli görüntüden oluşmaktadır. Analizlerimiz için EuroSAT veri setini seçmemizin en büyük sebeplerinden birisi oldukça kapsamlı bir örnek veri yapısına sahip olması ve coğrafi referansa sahip olmasıdır. Veri seti bünyesinde hem RGB hem de çoklu-spektral formatta verileri bulundurmaktadır. Bu çalışmada seçtiğimiz diğer veri seti ve kendi birleştireceğimiz veri seti ile uygunluğunu dikkate alarak RGB formattaki veriler kullanılarak analizler gerçekleştirildi. EuroSAT veri setinde bulunan 10 farklı sınıf etiketi ile sınıflandırma çalışmalarında birçok farklı metot kullanıldı. Bunlar transfer öğrenmesi uygulamaları için ResNet-18, GoogLeNet, VGG-16, MobileNetV2, DenseNet-201, AlexNet derin sinir ağlarıdır.

EuroSAT veri seti üzerinde yapılan derin öğrenme tabanlı sınıflandırma işlemlerinde altı farklı transfer öğrenmesi algoritması uygulanmıştır. Bu farklı algoritmalar sonucunda en yüksek sınıflandırma başarısı Şekil 5.2’de görüldüğü gibi %98.11 başarı oranı ile DenseNet-201 ağı kullanılarak elde edilmiştir. Veri seti çok kapsamlı ve veri sayısı çok fazla olduğu için her ağ yapısının çalışma koşulları aynı olmamaktadır ve ağ derinliği arttıkça sistem gereksinimleri artmaktadır. Veri setinin geniş boyutlu olması ve RGB görüntülerin işlenmesi zorluklarından dolayı çalışma yüksek sistem gereksinimleri gerektirmektedir. Bu nedenle ağ yapıları oldukça uzun sürelerde analiz edilmiş ve grafiklerin doyuma ulaştıkları noktalarda

analizler sonlandırılmıştır. Densenet-201 ağından sonra sırasıyla en başarılı derin öğrenme ağları Tablo 5.1’de görüldüğü gibi ResNet-18, MobileNetV2, AlexNet ve GoogLeNet derin öğrenme ağlarıdır. Kullandığımız uzaktan algılama ve uydu görüntüsü veri setinde analiz amaçlı deneğimiz transfer öğrenmesi metotlarından en başarısız olanı %93.50 başarı oranı ile VGG-16 derin öğrenme ağıdır.



Şekil 5.2. EuroSAT veri için DenseNet-201 derin ağı sınıflandırma uygulaması


Tablo 5.1. EuroSAT veri seti sınıflandırma sonuçları

Veri Seti	Metot	Optimizasyon Algoritması	Doğruluk(%)
EuroSAT	ResNet-18	SGDM	97.87
	VGG-16	SGDM	93.50
	DenseNet-201	SGDM	98.11
	AlexNet	SGDM	96.78
	GoogLeNet	SGDM	96.76
	MobileNetV2	SGDM	97.41

5.2. AID Veri Seti İçin Sınıflandırma Sonuçları

AID veri seti farklı ortamlardan oluşan hem endüstriyel yapılar hem de doğal ortamları kapsayan 30 sınıf ve 10000 adet etiketli görüntüden oluşmaktadır. AID veri setini seçmemizdeki temel etkenlerden bir tanesi sınıf çeşitliliği olarak oldukça çeşitli olması ve çalışmamızda analiz etmeyi hedeflediğimiz birleşmiş veri seti için birleştirilmeye uygun olmasıdır. Veri seti bünyesinde RGB formatta görüntüler bulundurmaktadır. Sınıflandırma analizlerimiz diğer veri setimiz ve birleşmiş veri setinde de olacağı gibi RGB görüntüler üzerinden gerçekleştirilmektedir. AID veri setinde 30 farklı sınıf etiketi üzerinden sınıflandırma yapmak amacıyla altı farklı derin öğrenme metodu kullanıldı. Bunlar transfer öğrenmesi uygulamaları için ResNet-18, GoogLeNet, VGG-16, MobileNetV2, DenseNet-201, AlexNet derin sinir ağlarıdır.

AID veri seti üzerinde sınıflandırma amaçlı uygulanan derin öğrenme tabanlı sınıflandırma algoritmaları sonucunda en yüksek sınıflandırma başarısı Şekil 5.3’de görüldüğü gibi DenseNet-201 derin öğrenme ağı kullanılarak elde edilmiştir. Sınıflandırma işlemi DenseNet201 ağı ile gerçekleştirildiğinde sınıflandırma başarısı %96.10 olarak elde edilmiştir. Çalışmamızda analiz ettiğimiz bir diğer veri seti olan EuroSAT veri setinde yapılan analizlerde yine DenseNet-201 derin öğrenme ağı en başarılı sınıflandırma sonucunu elde ettiğimiz sinir ağıymızdı. Bu durumdan uydu görüntüsü ve uzaktan algılama tabanlı veri setlerinde DenseNet-201 ağının çalışmamızda denediğimiz diğer ağlardan daha başarılı bir sınıflandırma gerçekleştirdiği yorumunu yapabiliriz. Bu başarının başlıca sebeplerinden bir tanesi ağ yapısından kaynaklıdır. DenseNET-201 ağ yapısı olarak incelendiğinde bir katmana kendisinden önceki bütün katmanlardan bilgi girişi vardır ve bu sayede bir özneteliği tekrar kullanmaya teşvik etme avantajına sahiptir. Densenet-201 ağından sonra sırasıyla en başarılı derin öğrenme ağları Tablo 5.2’de görüldüğü gibi MobileNetV2, ResNet-18, VGG-16 ve GoogLeNet derin öğrenme ağlarıdır. Kullandığımız uzaktan algılama ve uydu görüntüsü veri setinde analiz amaçlı denediğimiz transfer öğrenmesi metodlarından en başarısız olanı %90.05 başarı oranı ile AlexNet derin öğrenme ağıdır.



Şekil 5.3. AID veri seti için DenseNet-201 derin ağı sınıflandırma uygulaması

Tablo 5.2. AID veri seti sınıflandırma sonuçları

Veri Seti	Metot	Optimizasyon Algoritması	Doğruluk(%)
AID	DenseNet-201	SGDM	96.10
	ResNet-18	SGDM	92.55
	AlexNet	SGDM	90.05
	GoogLeNet	SGDM	90.15
	VGG-16	SGDM	90.45
	MobileNetV2	SGDM	93.90


5.3. Birleşik Veri Seti İçin Sınıflandırma Sonuçları

Birleşik veri seti EuroSAT ve AID veri setlerinin birleştirilmesiyle oluşturulmuş 37 sınıf ve 12100 adet etiketlenmiş veriye sahip bir veri setidir. Bu veri setini oluşturmamızdaki temel amaç sınıflandırma başarısının artan sınıf sayısına göre değişimini incelemektir. Veri seti oluşturulurken seçilen iki veri seti başlıca uydu görüntüsü ve uzaktan algılama alanında kapsamlı bir veri havuzuna sahip olmaları ve sınıf etiketi benzerliklerinden dolayı seçilmiştir. Bu seçim sırasında birleştirme kolaylığı dikkate alınmıştır. Veri setleri birleştirilirken EuroSAT veri setinde AID veri setinden farklı olan 7 sınıf etiketinden 300'er

adet görüntü alınarak AID veri setinin mevcut 30 sınıfı üzerine eklenmiş ve sonucunda 37 sınıfa sahip yeni bir veri seti oluşturulmuştur. Bütün veriler diğer iki veri setimizdeki gibi RGB formatında olup analizler bu formattaki veriler üzerinden gerçekleştirilmiştir. Birleşik veri seti üzerinde birçok sınıflandırma analizi gerçekleştirildi. Bunlar transfer öğrenmesi uygulamaları için ResNet-18, GoogLeNet, VGG-16, MobileNetV2, DenseNet-201, AlexNet derin sinir ağlarıdır. Makine öğrenmesi tabanlı sınıflandırma çalışmalarında ise K-En Yakın Komşuluk Algoritmaları, Karar Ağaçları, Destek Vektör Makineleri, Topluluk Metotları ve Naive Bayes Algoritmaları gerçekleştirilmiştir. Birleşik veri setimizde diğer iki veri setimizden ayrı olarak derin öğrenme ile öznetelik çıkararak makine öğrenmesi yöntemleri ile sınıflandırma metotları da analiz edilmiştir. Bu ekstra çalışmanın sebebi veri setimizde derin öğrenme algoritmaları ve derin öğrenme algoritmaları yardımıyla çıkarılmış öznetelikler kullanılarak uygulanan makine öğrenmesi algoritmalarının başarılarının kıyaslanmasıdır.

5.3.1. Birleşik veri seti için derin öğrenme tabanlı sınıflandırma sonuçları

Birleşik veri seti üzerinde altı farklı derin öğrenme algoritması sınıflandırma çalışmaları amacıyla gerçekleştirilmiştir. Bu çok sayıda farklı algoritma sonucunda diğer iki veri setimizde gördüğümüz sonuçlarla benzer şekilde birleşik veri setinde en başarılı derin öğrenme ağı Şekil 5.4’de gözlendiği gibi %96.20 sınıflandırma başarısı ile DenseNet-201 derin öğrenme ağıdır. Bu analizin sonucunda AID veri setine bünyesinde bulunan sınıflardan farklı olarak EuroSAT veri setinden 7 adet sınıf eklediğimizde elde ettiğimiz sınıflandırma başarısının AID veri setinin mevcut önceki sınıflandırma başarısına kıyasla daha yüksek olduğunu görmekteyiz. Bunun sonucu olarak yaptığımız çalışmada sınıf sayısını artırmanın başarı kriteri olarak AID veri setine göre daha yüksek başarı sunduğunu söylemek mümkündür. Densenet-201 ağından sonra sırasıyla en başarılı derin ağlar Tablo 5.3’de görüldüğü gibi MobileNetV2, ResNet-18, VGG-16 ve GoogLeNet derin öğrenme ağlarıdır. Kullandığımız uzaktan algılama ve uydu görüntüsü veri setinde analiz amaçlı denediğimiz transfer öğrenmesi metotlarından en başarısız olanı %87.52 başarı oranı ile AlexNet derin öğrenme ağıdır.



Şekil 5.4. Birleşik veri seti için DenseNet-201 derin ağı uygulaması

Tablo 5.3. Birleşik veri seti sınıflandırma sonuçları

Metot	Optimizasyon Algoritması	Doğruluk(%)
DenseNet-201	SGDM	96.20
AlexNet	SGDM	87.52
ResNet-18	SGDM	92.2
MobileNetV2	SGDM	94.35
GoogLeNet	SGDM	91.53
VGG-16	SGDM	91.74


5.3.2. Birleşik veri seti için makine öğrenmesi tabanlı sınıflandırma sonuçları

Birleşik veri seti üzerinde yapılan makine öğrenme tabanlı sınıflandırma işlemlerinde birçok farklı derin öğrenme algoritmaları kullanılarak öznelilikler çıkartılmış ve çıkarılan bu öznelilikler makine öğrenmesi tabanlı sınıflandırıcılara iletilmiştir. Buradaki temel amaç birleştirdiğimiz veri seti üzerinde makine öğrenmesi temelli sınıflandırma ve derin öğrenme temelli sınıflandırma başarılarını kıyaslamaktır. Bu çalışmada AlexNet, DenseNet-201 ve

ResNet-18 derin öğrenme ağları kullanılarak öznelik çıkarımları gerçekleştirilmiş ve sonrasında makine öğrenmesi tabanlı sınıflandırıcılara sunulmuştur. Bu çalışmada bizim için en yüksek beklentiye sahip olduğumuz ve en önemli derin öğrenme ağı daha önceki analizlerimizdeki başarısından dolayı DenseNet-201 derin öğrenme ağıdır. DenseNet201 ağı ile çıkarılan öznelikler sonucu makine öğrenmesi uygulamaları gerçekleştirildiğinde Tablo 5.4’de gördüğümüz gibi en başarılı sınıflandırıcılar %94.9 sınıflandırma başarısı ile Topluluk Metotları ve Lineer Diskriminant uygulamaları olarak görülmektedir. Bu uygulamaları %93.5 başarı oranı ile DVM algoritması takip etmektedir. Topluluk metotları ile sınıflandırma sonucu oluşan karışıklık matrisi Şekil 5.5’de görülmektedir. Karışıklık matrisi incelendiğinde uygulamamızın sınıflandırma konusunda en çok hatayı park ve dinlenme tesisi sınıf etiketlerinde yaptığı görülmektedir.

Tablo 5.4. Birleşik veri seti için DenseNet-201 kullanılarak çıkarılan öznelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları

Öznelik Çıkarma Yöntemi	Sınıflandırma Yöntemi	Doğruluk(%)
DenseNet-201	Karar Ağaçları	45.2
	Linear Discriminant	94.9
	Naive Bayes	87.3
	DVM	93.5
	KNN	89.9
	Topluluk Metotları	94.9



Şekil 5.5. Birleşik veri seti için DenseNet-201 kullanılarak çıkarılan öznetelikler ile topluluk metotları uygulaması karmaşıklık matrisi

Öznitelik çıkarımı amacıyla kullandığımız bir diğer derin öğrenme ağıımız ResNet-18 olarak seçilmiştir. Derin öğrenme ağı ile öznitelik çıkarımı sonucunda makine öğrenmesi uygulandığında en başarılı sınıflandırıcı Destek Vektör Makineleri olarak gözlenmektedir ve sınıflandırma başarısı %88.7’dir. Diğer makine öğrenmesi metotlarının sınıflandırma başarıları Tablo 5.5’de gözlenmektedir. Linear Discriminant uygulamasının karışıklık matrisi Şekil 5.6’de gösterilmektedir. Karışıklık matrisi incelendiğinde sınıflandırma uygulamasında en çok hatanın park ve dinlenme tesislerinde yapıldığı görülmektedir.


Tablo 5.5. Birleşik veri seti için ResNet-18 kullanılarak çıkarılan öznitelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları

Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi	Doğruluk(%)
ResNet-18	Karar Ağaçları	35.8
	Linear Discriminant	88.4
	Naive Bayes	80.3
	DVM	88.7
	KNN	84.3
	Topluluk Metotları	88.0

Öznitelik çıkarımı amacıyla kullandığımız bir diğer derin öğrenme ağı ise AlexNet derin öğrenme ağıdır. AlexNet derin öğrenme ağı kullanılarak yapılan analizler Tablo 5.6’da gözlenmektedir. Uygulanan yöntemler sonucu en başarılı algoritma %88.0 başarı oranı ile Topluluk Metotları olarak gözlenmektedir. Topluluk metotlarından sonra en başarılı sınıflandırıcı %86.7 başarı oranı ile Destek Vektör Makineleri olarak gözlenmektedir. Topluluk Metotlarına ait karışıklık matrisi Şekil 5.7’de görülmektedir. Karışıklık matrisi dikkate alındığında sınıflandırma hatasının en çok park ve okul sınıflarında meydana geldiği görülmektedir. Ayrıca derin öğrenme ile öznitelik çıkararak makine öğrenmesi tabanlı sınıflandırma yöntemini uyguladığımızda yöntemlerin birçoğunda başarı düşüşü meydana geldiği gözlenmektedir. Yalnızca AlexNet ile öznitelik çıkarma uygulamamızda başarı oranımız AlexNet ile derin öğrenme uygulamasına kıyasla artışa uğramıştır. Analizlerin geneline bakıldığında Derin Öğrenme tabanlı sınıflandırma başarı oranları daha yüksek gözlenmektedir.

Tablo 5.6. Birleşik veri seti için AlexNet kullanılarak çıkarılan öznitelikler ile makine öğrenmesi tabanlı sınıflandırma başarıları

Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi	Doğruluk(%)
AlexNet	Karar Ağaçları	35.3
	Linear Discriminant	86.2
	DVM	86.7
	KNN	82.3
	Topluluk Metotları	88.0



Şekil 5.7. Birleşik veri seti için AlexNet kullanılarak çıkarılan öz nitelikler ile topluluk metotları uygulaması karmaşıklık matrisi

Literatürde uzaktan algılama ve uydu görüntüsü sınıflandırma alanında yapılan çalışmalar incelenmiştir ve konu kapsamında seçilen veri setleri ile yapılan çalışmalar mevcuttur [8], [14], [16], [17]. Literatürde incelenmiş çalışmalarda kullanılan metotlar ve sınıflandırma başarıları Tablo 5.7’de gösterilmiştir. Tabloda veri setleri üzerinde yapılan analizler incelenmektedir. Çalışmanın öncelikli amacı birleştirilmiş bir veri seti üzerinde sınıf artışına bağlı başarı oranı değişimidir. Birleşik veri seti oluşturulurken AID veri seti üzerine bünyesinde bulunmayan 7 farklı sınıf EuroSAT veri setinden alınarak eklenmiş ve sınıflardaki görüntü sayısı AID veri setinin sınıf başına ortalama görüntü sayısına uygun seçilmiştir. Birleşik veri seti analizleri sonucunda %96.20 sınıflandırma doğruluğu elde edilerek AID veri setine göre sınıf sayısında artış ile birlikte başarı oranında da artış elde edildiği gözlenmektedir.

Tablo 5.7.Literatürde yapılan çalışmalar ve başarı sonuçları

Veri Seti	Yıl-Yazar	Sınıf Sayısı	Sınıflandırma Yöntemi	Sınıflandırma Başarısı
AID	2019-Helber et al.	30	GoogLeNet	%87.60
	2016-Xia et al.		VGG-VD-16	%89.64
	Yapılan Çalışma		DenseNet-201	%96.10
EuroSAT	2019-Helber et al.	10	ResNet-50	%98.57
	2020-Yamashkin et al.		InceptionV3	%97.93
	Yapılan Çalışma		DenseNet-201	%98.11
Birleşik Veri Seti	Yapılan Çalışma	37	DenseNet-201	%96.20

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında seçilen 3 farklı veri seti bünyesinde bulunan uzaktan algılama ve uydu görüntüleri üzerinde sınıflandırma işlemleri yapılarak sınıflandırma başarılarının karşılaştırılması amaçlanmıştır. Çalışmada erişime ve açık ve seçilen iki farklı veri setinin uygun koşullar dikkate alınarak birleştirilmiş halinden oluşan bir birleşik veri seti üzerinde analizler gerçekleştirilmiştir. Uzaktan algılama işlemi oldukça karışık bir işlemdir. Bu konu kapsamında görüntülerin sıradan görüntülerden farklı olarak geniş coğrafi alanlar içermesi nesne boyutlarındaki büyüklükler ve çözünürlük gibi birçok problem sınıflandırma başarısını doğrudan etkilemektedir. Çalışmada transfer öğrenmesi kullanılarak önceden eğitilmiş derin öğrenme ağlarının veri setleri üzerindeki sınıflandırma başarılarının karşılaştırılmasına ek olarak birleşik veri setindeki sınıf artışına göre başarı oranındaki değişiklik analiz edilmek istenmiştir. Buna ek olarak birleşik veri seti üzerinde transfer öğrenmesi tabanlı sınıflandırma ile birlikte derin ağlar ile çıkarılan öznitelikleri kullanarak makine öğrenmesi tabanlı sınıflandırma işlemleri de gerçekleştirilmiştir. Bu işlemin amacı derin ağlar ile sınıflandırma ve makine öğrenmesi tabanlı sınıflandırma arasındaki performans farkını gözlemlemektir.

Yapılan analizlerde hem açık erişimli EuroSAT ve AID veri setlerinde hem de uygun koşullarda birleştirilen birleşik veri setinde yapılan analizlerde görülmektedir ki sınıflandırma sonucu tüm veri setleri için en yüksek DenseNet-201 derin öğrenme ağı kullanılarak elde edilmektedir. DenseNet-201 derin öğrenme ağı ile yapılan sınıflandırmada EuroSAT veri seti için %98.11 ve AID veri seti için %96.10 sınıflandırma başarıları gözlenmektedir. Birleşik veri setinde yapılan analizlerde derin öğrenme tabanlı sınıflandırma işlemlerinde en yüksek başarı %96.20 ile DenseNet-201 ağı ile elde edilmekte ve makine öğrenmesi tabanlı sınıflandırma işleminde ise en yüksek başarı oranı %94.9 ile Linear Discriminant ve Topluluk Metotları kullanılarak elde edilmektedir. Bu analizler sonucunda görülmektedir ki derin öğrenme tabanlı sınıflandırma veri birleşik veri seti için makine öğrenme tabanlı sınıflandırmaya göre daha başarılı bir sınıflandırıcıdır. Birleşik veri setinde sınıf sayısındaki artışın başarı oranına etkisi incelenmek amaçlanmış ve yapılan analizler sonucunda AID veri setine göre sınıflandırma açısından daha başarılı olduğu gözlenmiştir. DenseNet-201 ağının veri setleri üzerindeki başarısı dikkate alındığında çalışmadaki analizler içinde kullanılan tüm veri setleri için en başarılı sınıflandırıcı derin öğrenme ağı olduğunu söylemek mümkündür.

Literatürde bulunan uydu görüntüsü sınıflandırma çalışmaları ile yapılan çalışma arasındaki temel farklılık bir veri setine bağlı kalmayarak iki farklı veri seti ile sınıf sayısını artırmak ve başarı oranına fayda sağlamaktır. Gelecek çalışmalarda anlaşılır ve sınıflandırılabilir veriler ile sınıf sayısında artışlara giderek ve farklı derin ağ metotları kullanılarak daha başarılı sonuçlar elde edilebileceği düşünülmektedir.



7. KAYNAKÇA

- [1] M. A. Kadhim and M. H. Abed, *Convolutional neural network for satellite image classification*, vol. 830, no. April 2019. Springer International Publishing, 2020.
- [2] M. Nair and B. J.S., “Supervised Techniques and Approaches for Satellite Image Classification,” *Int. J. Comput. Appl.*, vol. 134, no. 16, pp. 1–6, 2016, doi: 10.5120/ijca2016908202.
- [3] I. Turkoglu, “Derin öğrenme ile uydu görüntülerinin siniflandırılması,” no. December, 2019.
- [4] A. K. Rai, N. Mandal, A. Singh, and K. K. Singh, “Landsat 8 OLI Satellite Image Classification using Convolutional Neural Network,” *Procedia Comput. Sci.*, vol. 167, no. 2019, pp. 987–993, 2020, doi: 10.1016/j.procs.2020.03.398.
- [5] M. Pritt and G. Chern, “Satellite image classification with deep learning,” *Proc. - Appl. Imag. Pattern Recognit. Work.*, vol. 2017-Octob, pp. 1–7, 2018, doi: 10.1109/AIPR.2017.8457969.
- [6] D. Dai and W. Yang, “Satellite image classification via two-layer sparse coding with biased image representation,” *IEEE Geosci. Remote Sens. Lett.*, vol. 8, no. 1, pp. 173–176, 2011, doi: 10.1109/LGRS.2010.2055033.
- [7] S. Manthira Moorthi, I. Misra, R. Kaur, N. P. Darji, and R. Ramakrishnan, “Kernel based learning approach for satellite image classification using support vector machine,” *2011 IEEE Recent Adv. Intell. Comput. Syst. RAICS 2011*, vol. 0, no. x, pp. 107–110, 2011, doi: 10.1109/RAICS.2011.6069282.
- [8] G. S. Xia *et al.*, “AID: A benchmark data set for performance evaluation of aerial scene classification,” *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 7, pp. 3965–3981, 2017, doi: 10.1109/TGRS.2017.2685945.
- [9] A. O. Tarasenko, Y. V. Yakimov, and V. N. Soloviev, “Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification,” *CEUR Workshop Proc.*, vol. 2546, no. 2, pp. 101–114, 2019.
- [10] E. Maggiori, S. Member, G. Charpiat, Y. Tarabalka, and P. Alliez, “Recurrent Neural Networks to Correct Satellite Image Classification Maps,” pp. 1–10, 2017.
- [11] D. Duarte, F. Nex, N. Kerle, and G. Vosselman, “Satellite Image Classification of Building Damages Using Airborne,” *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. IV, no. June 2018, pp. 4–7, 2020, [Online]. Available:

<https://research.utwente.nl/en/publications/satellite-image-classification-of-building-damages-using-airborne>.

- [12] S. Roy, E. Sangineto, N. Sebe, and B. Demir, “Semantic-fusion gans for semi-supervised satellite image classification,” *Proc. - Int. Conf. Image Process. ICIP*, pp. 684–688, 2018, doi: 10.1109/ICIP.2018.8451836.
- [13] A. Unnikrishnan, V. Sowmya, and K. P. Soman, “Deep alexnet with reduced number of trainable parameters for satellite image classification,” *Procedia Comput. Sci.*, vol. 143, pp. 931–938, 2018, doi: 10.1016/j.procs.2018.10.342.
- [14] P. Helber, B. Bischke, A. Dengel, and D. Borth, “Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 12, no. 7, pp. 2217–2226, 2019, doi: 10.1109/JSTARS.2019.2918242.
- [15] Q. Liu *et al.*, “DeepSat V2: feature augmented convolutional neural nets for satellite image classification,” *Remote Sens. Lett.*, vol. 11, no. 2, pp. 156–165, 2020, doi: 10.1080/2150704X.2019.1693071.
- [16] E. Charou *et al.*, “Deep Learning for Agricultural Land Detection in Insular Areas,” *10th Int. Conf. Information, Intell. Syst. Appl. IISA 2019*, no. July, 2019, doi: 10.1109/IISA.2019.8900670.
- [17] S. A. Yamashkin, A. A. Yamashkin, V. V. Zanozin, M. M. Radovanovic, and A. N. Barmin, “Improving the efficiency of deep learning methods in remote sensing data analysis: Geosystem approach,” *IEEE Access*, vol. 8, pp. 179516–179529, 2020, doi: 10.1109/ACCESS.2020.3028030.
- [18] R. G. Babu, K. U. Maheswari, C. Zarro, B. D. Parameshachari, and S. L. Ullo, “Land-Use and Land-Cover Classification Using a Human Group-Based Particle Swarm Optimization Algorithm with an LSTM Classifier on Hybrid Pre-Processing Remote-Sensing Images,” *Remote Sens.*, vol. 12, no. 24, pp. 1–28, 2020, doi: 10.3390/rs12244135.
- [19] H. Yassine, K. Tout, and M. Jaber, “Improving LULC classification from satellite imagery using deep learning - Eurosat dataset,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 43, no. B3-2021, pp. 369–376, 2021, doi: 10.5194/isprs-archives-XLIII-B3-2021-369-2021.
- [20] Y. Zhang and G. Xu, “Singular Value Decomposition,” *Encycl. Database Syst.*, vol. 7, no. 2, pp. 1–3, 2016, doi: 10.1007/978-1-4899-7993-3_538-2.
- [21] S. Voigt, T. Kemper, T. Riedlinger, R. Kiefl, K. Scholte, and H. Mehl, “Satellite

- image analysis for disaster and crisis-management support,” *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 6, pp. 1520–1528, 2007, doi: 10.1109/TGRS.2007.895830.
- [22] H. Demirel and G. Anbarjafari, “Discrete wavelet transform-based satellite image resolution enhancement,” *IEEE Trans. Geosci. Remote Sens.*, vol. 49, no. 6 PART 1, pp. 1997–2004, 2011, doi: 10.1109/TGRS.2010.2100401.
- [23] J. A. Richards and Xiuping Jia, *Remote Sensing Digital Image Analysis*. Springer International Publishing, 2006.
- [24] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. Pearson, 2008.
- [25] “Resolution,” *University of Michigan Library*. .
- [26] K. Jacobsen, “High Resolution Satellite Imaging Systems - Overview,” *Photogramm. Fernerkundung Geoinf. PFG*, vol. 6, no. 6, pp. 487–496, 2005, [Online]. Available: http://www.ipi.uni-hannover.de/uploads/tx_tkpublikationen/038-jacobsen.pdf.
- [27] S. Borra, R. Thanki, and N. Dey, *Satellite Image Analysis: Clustering and Classification*. Springer, 2019.
- [28] N. Verde, G. Mallinis, M. Tsakiri-Strati, C. Georgiadis, and P. Patias, “Assessment of radiometric resolution impact on remote sensing data classification accuracy,” *Remote Sens.*, vol. 10, no. 8, pp. 1–17, 2018, doi: 10.3390/rs10081267.
- [29] G. Wang and Q. Weng, *REMOTE SENSING of Natural Resources*. CRC Press, 2014.
- [30] M.V.K. Sivakumar, P.S. Roy, K. Harmsen, and S.K. Saha, Eds., *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*. World Meteorological Organisation, 2004.
- [31] C. Elachi and Jakob Van Zyl, *Introduction To The Physics And Techniques Of Remote Sensing*. Wiley, 2021.
- [32] D. Michie, C. C. Taylor, and D.J. Spiegelhalter, *Machine Learning, Neural and Statistical Classification*. Overseas Press, 1994.
- [33] O. Ahmed and A. Brifcani, “Gene Expression Classification Based on Deep Learning,” *4th Sci. Int. Conf. Najaf, SICN 2019*, pp. 145–149, 2019, doi: 10.1109/SICN47020.2019.9019357.
- [34] H. Data *et al.*, “Deep Learning-Based Classification of Deep Learning-Based Classification of Hyperspectral Data,” vol. 7, no. June 2014, pp. 1–14, 2015.
- [35] H. Ismail Fawaz, G. Forestier, J. Weber, L. Idoumghar, and P. A. Muller, “Deep learning for time series classification: a review,” *Data Min. Knowl. Discov.*, vol. 33, no. 4, pp. 917–963, 2019, doi: 10.1007/s10618-019-00619-1.
- [36] R. Zebari, A. Abdulazeez, D. Zeebaree, D. Zebari, and J. Saeed, “A Comprehensive

- Review of Dimensionality Reduction Techniques for Feature Selection and Feature Extraction,” *J. Appl. Sci. Technol. Trends*, vol. 1, no. 2, pp. 56–70, 2020, doi: 10.38094/jastt1224.
- [37] S. Khalid, T. Khalil, and S. Nasreen, “A survey of feature selection and feature extraction techniques in machine learning,” *Proc. 2014 Sci. Inf. Conf. SAI 2014*, pp. 372–378, 2014, doi: 10.1109/SAI.2014.6918213.
- [38] J. Sklansky, “Image segmentation and feature extraction,” *IEEE Trans. Syst. Man Cybern.*, vol. 8, no. 4, pp. 237–246, 1978, doi: 10.1109/TSMC.1978.4309944.
- [39] M. Hussain, J. J. Bird, and D. R. Faria, “A study on CNN transfer learning for image classification,” *Adv. Intell. Syst. Comput.*, vol. 840, pp. 191–202, 2019, doi: 10.1007/978-3-319-97982-3_16.
- [40] A. Lumini and L. Nanni, “Deep learning and transfer learning features for plankton classification,” *Ecol. Inform.*, vol. 51, no. February, pp. 33–43, 2019, doi: 10.1016/j.ecoinf.2019.02.007.
- [41] S. J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345–1359, 2010, doi: 10.1109/TKDE.2009.191.
- [42] H. I. Fawaz, G. Forestier, J. Weber, L. Idoumghar, and P. A. Muller, “Transfer learning for time series classification,” *Proc. - 2018 IEEE Int. Conf. Big Data, Big Data 2018*, pp. 1367–1376, 2019, doi: 10.1109/BigData.2018.8621990.
- [43] U. Côté-Allard *et al.*, “Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 27, no. 4, pp. 760–771, 2019, doi: 10.1109/TNSRE.2019.2896269.
- [44] S. U. Khan, N. Islam, Z. Jan, I. Ud Din, and J. J. P. C. Rodrigues, “A novel deep learning based framework for the detection and classification of breast cancer using transfer learning,” *Pattern Recognit. Lett.*, vol. 125, pp. 1–6, 2019, doi: 10.1016/j.patrec.2019.03.022.
- [45] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” Aug. 2016, [Online]. Available: <http://arxiv.org/abs/1608.06993>.
- [46] K. Zhang, Y. Guo, X. Wang, J. Yuan, and Q. Ding, “Multiple feature reweight DenseNet for image classification,” *IEEE Access*, vol. 7, pp. 9872–9880, 2019, doi: 10.1109/ACCESS.2018.2890127.
- [47] G. Huang, S. Liu, L. Van Der Maaten, and K. Q. Weinberger, “CondenseNet: An Efficient DenseNet using Learned Group Convolutions.”

- [48] S. Lu, Z. Lu, and Y. D. Zhang, "Pathological brain detection based on AlexNet and transfer learning," *J. Comput. Sci.*, vol. 30, pp. 41–47, 2019, doi: 10.1016/j.jocs.2018.11.008.
- [49] M. Z. Alom *et al.*, "The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches," 2018, [Online]. Available: <http://arxiv.org/abs/1803.01164>.
- [50] S. H. Wang *et al.*, "Alcoholism identification based on an Alexnet transfer learning model," *Front. Psychiatry*, vol. 10, no. APR, pp. 1–13, 2019, doi: 10.3389/fpsyt.2019.00205.
- [51] R. U. Khan, X. Zhang, and R. Kumar, "Analysis of ResNet and GoogleNet models for malware detection," *J. Comput. Virol. Hacking Tech.*, vol. 15, no. 1, pp. 29–37, 2019, doi: 10.1007/s11416-018-0324-z.
- [52] C. Szegedy *et al.*, "Going deeper with convolutions," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07-12-June, pp. 1–9, 2015, doi: 10.1109/CVPR.2015.7298594.
- [53] International Association for Pattern Recognition, International Conference on Document Analysis and Recognition 13 2015.08.23-26 Nancy, IAPR International Conference on Document Analysis & Recognition 13 2015.08.23-26 Nancy, and ICDAR 13 2015.08.23-26 Nancy, "基于GoogLeNet和方向特征映射的高性能脱机手写体汉字识别," pp. 846–850, 2015.
- [54] P. Salavati and H. M. Mohammadi, "Obstacle detection using GoogleNet," *2018 8th Int. Conf. Comput. Knowl. Eng. ICCKE 2018*, no. Iccke, pp. 326–332, 2018, doi: 10.1109/ICCKE.2018.8566315.
- [55] P. Tang, H. Wang, and S. Kwong, "G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition," *Neurocomputing*, vol. 225, pp. 188–197, 2017, doi: 10.1016/j.neucom.2016.11.023.
- [56] N. Schaetti, "Character-based convolutional neural network and res: Net 18 for Twitter Author Profiling: Notebook for PAN at CLEF 2018," *CEUR Workshop Proc.*, vol. 2125, no. September, 2018.
- [57] Ö. Er, "Hava ve Uydu Görüntüleri Üzerinde Derin Öğrenme Tabanlı Araç Tespit ve Sınıflandırması," Gazi Üniversitesi, 2020.
- [58] Q. A. Al-Haija, M. A. Smadi, and S. Zein-Sabatto, "Multi-Class Weather Classification Using ResNet-18 CNN for Autonomous IoT and CPS Applications,"

- Proc. - 2020 Int. Conf. Comput. Sci. Comput. Intell. CSCI 2020*, no. DL, pp. 1586–1591, 2020, doi: 10.1109/CSCI51800.2020.00293.
- [59] X. Yu and S. H. Wang, “Abnormality Diagnosis in Mammograms by Transfer Learning Based on ResNet18,” *Fundam. Informaticae*, vol. 168, no. 2–4, pp. 219–230, 2019, doi: 10.3233/FI-2019-1829.
 - [60] Q. Xiang, G. Zhang, X. Wang, J. Lai, R. Li, and Q. Hu, “Fruit image classification based on Mobilenetv2 with transfer learning technique,” *ACM Int. Conf. Proceeding Ser.*, 2019, doi: 10.1145/3331453.3361658.
 - [61] C. H. Karadal, M. C. Kaya, T. Tuncer, S. Dogan, and U. R. Acharya, “Automated classification of remote sensing images using multileveled MobileNetV2 and DWT techniques,” *Expert Syst. Appl.*, vol. 185, no. July, p. 115659, 2021, doi: 10.1016/j.eswa.2021.115659.
 - [62] F. Saxen, P. Werner, S. Handrich, E. Othman, L. Dinges, and A. Al-Hamadi, “Face attribute detection with mobilenetv2 and nasnet-mobile,” *Int. Symp. Image Signal Process. Anal. ISPA*, vol. 2019-Sept, pp. 176–180, 2019, doi: 10.1109/ISPA.2019.8868585.
 - [63] M. Akay *et al.*, “Deep Learning Classification of Systemic Sclerosis Skin Using the MobileNetV2 Model,” *IEEE Open J. Eng. Med. Biol.*, vol. 2, pp. 104–110, 2021, doi: 10.1109/ojemb.2021.3066097.
 - [64] C. Buiu, V. R. Dănilă, and C. N. Răduță, “MobileNetV2 ensemble for cervical precancerous lesions classification,” *Processes*, vol. 8, no. 5, 2020, doi: 10.3390/PR8050595.
 - [65] M. Toğaçar, Z. Cömert, and B. Ergen, “Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks,” *Chaos, Solitons and Fractals*, vol. 144, p. 110714, 2021, doi: 10.1016/j.chaos.2021.110714.
 - [66] Q. Guan *et al.*, “Deep convolutional neural network VGG-16 model for differential diagnosing of papillary thyroid carcinomas in cytological images: A pilot study,” *J. Cancer*, vol. 10, no. 20, pp. 4876–4882, 2019, doi: 10.7150/jca.28769.
 - [67] L. Geng, S. Zhang, J. Tong, and Z. Xiao, “Lung segmentation method with dilated convolution based on VGG-16 network,” *Comput. Assist. Surg.*, vol. 24, no. sup2, pp. 27–33, 2019, doi: 10.1080/24699322.2019.1649071.
 - [68] S. Tammina, “Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images,” *Int. J. Sci. Res. Publ.*, vol. 9, no. 10, p. p9420, 2019, doi: 10.29322/ijsrp.9.10.2019.p9420.

- [69] B. Rao, "Machine Learning Algorithms: A Review," *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, no. 3, pp. 1174–1179, 2016, doi: 10.21275/ART20203995.
- [70] G. Shobha and S. Rangaswamy, *Machine Learning*, 1st ed., vol. 38. Elsevier B.V., 2018.
- [71] I. El Naqa and M. J. Murphy, "Machine Learning in Radiation Oncology," *Mach. Learn. Radiat. Oncol.*, pp. 3–11, 2015, doi: 10.1007/978-3-319-18305-3.
- [72] M. J. Aitkenhead, "A co-evolving decision tree classification method," *Expert Syst. Appl.*, vol. 34, no. 1, pp. 18–25, 2008, doi: 10.1016/j.eswa.2006.08.008.
- [73] C. E. Brodley and M. A. Friedl, "Decision tree classification of land cover from remotely sensed data," *Remote Sens. Environ.*, vol. 61, no. 3, pp. 399–409, 1997, doi: 10.1016/S0034-4257(97)00049-7.
- [74] Z. H. Zhou and Z. Q. Chen, "Hybrid decision tree," *Knowledge-Based Syst.*, vol. 15, no. 8, pp. 515–528, 2002, doi: 10.1016/S0950-7051(02)00038-2.
- [75] G. Rozenberg, T. Back, and J. N. Kok, *Handbook of Natural Computing*, vol. 1–4, no. January 2012. 2012.
- [76] G. M. Foody and A. Mathur, "Toward intelligent training of supervised image classifications: Directing training data acquisition for SVM classification," *Remote Sens. Environ.*, vol. 93, no. 1–2, pp. 107–117, 2004, doi: 10.1016/j.rse.2004.06.017.
- [77] M. Pal and G. M. Foody, "Feature selection for classification of hyperspectral data by SVM," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 5, pp. 2297–2307, 2010, doi: 10.1109/TGRS.2009.2039484.
- [78] A. Moldagulova and R. B. Sulaiman, "Using KNN algorithm for classification of textual documents," *ICIT 2017 - 8th Int. Conf. Inf. Technol. Proc.*, pp. 665–671, 2017, doi: 10.1109/ICITECH.2017.8079924.
- [79] W. Xing and Y. Bei, "Medical Health Big Data Classification Based on KNN Classification Algorithm," *IEEE Access*, vol. 8, pp. 28808–28819, 2020, doi: 10.1109/ACCESS.2019.2955754.
- [80] S. D. Jadhav and H. P. Channe, "Comparative Study of K-NN, Naive Bayes and Decision Tree Classification Techniques," *Int. J. Sci. Res.*, vol. 5, no. 1, pp. 1842–1845, 2016, doi: 10.21275/v5i1.nov153131.
- [81] Y. Huang and L. Li, "Naive Bayes classification algorithm based on small sample set," *CCIS2011 - Proc. 2011 IEEE Int. Conf. Cloud Comput. Intell. Syst.*, no. 2, pp. 34–39, 2011, doi: 10.1109/CCIS.2011.6045027.
- [82] J. Vaidya, M. Kantarcıoğlu, and C. Clifton, "Privacy-preserving Naïve Bayes

- classification,” *VLDB J.*, vol. 17, no. 4, pp. 879–898, 2008, doi: 10.1007/s00778-006-0041-y.
- [83] J. Ren, S. D. Lee, X. Chen, B. Kao, R. Cheng, and D. Cheung, “Naïve bayes classification of uncertain data,” *Proc. - IEEE Int. Conf. Data Mining, ICDM*, no. 60703110, pp. 944–949, 2009, doi: 10.1109/ICDM.2009.90.
 - [84] Z. Muda, W. Yassin, M. N. Sulaiman, and N. I. Udzir, “Intrusion detection based on K-Means clustering and Naïve Bayes classification,” *2011 7th Int. Conf. Inf. Technol. Asia Emerg. Converg. Singul. Forms - Proc. CITA'11*, 2011, doi: 10.1109/CITA.2011.5999520.
 - [85] “SPEAKER INDEPENDENT SPEECH EMOTION RECOGNITION BY ENSEMBLE CLASSIFICATION Institute for Human-Machine Communication Technische Universität München,” *Communication*, pp. 0–3, 2005.
 - [86] M. Hosni, I. Abnane, A. Idri, J. M. Carrillo de Gea, and J. L. Fernández Alemán, “Reviewing ensemble classification methods in breast cancer,” *Comput. Methods Programs Biomed.*, vol. 177, pp. 89–112, 2019, doi: 10.1016/j.cmpb.2019.05.019.
 - [87] Q. Zou, Z. Wang, X. Guan, B. Liu, Y. Wu, and Z. Lin, “An approach for identifying cytokines based on a novel ensemble classifier,” *Biomed Res. Int.*, vol. 2013, 2013, doi: 10.1155/2013/686090.
 - [88] H. B. Shen and K. C. Chou, “Using ensemble classifier to identify membrane protein types,” *Amino Acids*, vol. 32, no. 4, pp. 483–488, 2007, doi: 10.1007/s00726-006-0439-2.
 - [89] H. Xiao, Z. Xiao, and Y. Wang, “Ensemble classification based on supervised clustering for credit scoring,” *Appl. Soft Comput. J.*, vol. 43, pp. 73–86, 2016, doi: 10.1016/j.asoc.2016.02.022.
 - [90] T. Fawcett, “An introduction to ROC analysis,” *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, 2006, doi: 10.1016/j.patrec.2005.10.010.
 - [91] S. Visa, B. Ramsay, A. Ralescu, and E. Van Der Knaap, “Confusion matrix-based feature selection,” *CEUR Workshop Proc.*, vol. 710, pp. 120–127, 2011.