



**DERİN ÖĞRENME KULLANARAK UZAKTAN ALGILAMA
GÖRÜNTÜLERİNDEKİ NESNELERİN TESPİTİ**

Atakan KÖREZ

DOKTORA TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2020

Atakan KÖREZ tarafından hazırlanan “DERİN ÖĞRENME KULLANARAK UZAKTAN ALGILAMA GÖRÜNTÜLERİNDEKİ NESNELERİN TESPİTİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Necaattin BARIŞÇI

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Başkan: Prof. Dr. O. Ayhan ERDEM

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Prof. Dr. A. Kürşad TÜRKER

Endüstri Mühendisliği Ana Bilim Dalı, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Aydın ÇETİN

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Uçman ERGÜN

Biyomedikal Mühendisliği Ana Bilim Dalı, Afyon Kocatepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 25/06/2020

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....
Prof. Dr. Sena YAŞYERLİ
Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

.....
Atakan KÖREZ

25/06/2020

DERİN ÖĞRENME KULLANILARAK UZAKTAN ALGILAMA GÖRÜNTÜLERİNDEKİ NESNELERİN TESPİTİ

(Doktora Tezi)

Atakan KÖREZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2020

ÖZET

Son yıllarda arazi planlaması, şehir görüntüleme, trafik izleme, tarım uygulamaları gibi çok çeşitli alanlarda sıkça kullanılmaya başlayan insansız hava araçlarından çekilen görüntülerde nesne tespiti işlemi, hava ve uydu görüntü analizi alanında artan bir ilgi ile karşılanmaktadır. Bu tez çalışmasında, uzaktan algılama görüntülerindeki nesnelere otomatik olarak tespit edilmesi için iki farklı nesne tespit modeli önerilmiştir. Önerilen ilk modelde, uzaktan algılama görüntüleri nesne tespiti konusunda oldukça başarılı sonuçlar almış olan Daha Hızlı Bölgesel Evrişimli Sinir Ağı (Daha Hızlı B-ESA) modeli yapısı temel alınmıştır. Bu yapının, insansız hava araçlarından çekilen görüntülerdeki nesne tespit performansının artırılmasına yönelik geliştirmeler yapılarak önerilen model nihai duruma getirilmiştir. Önerilen ikinci model ise, üç farklı derin öğrenme nesne tespit modelinin optimize edilmiş katsayı ağırlıklı nesne tespiti yapmasına olanak sağlayan işbirlikçi bir nesne tespit modelidir. Önerilen her iki nesne tespit modelinin, etkinliği, verimliliği ve katkısı, uzaktan algılama görüntülerinden oluşan Northwestern Polytechnical University Very High Resolution 10 (NWPU-VHR10) veri seti üzerinde yapılan testlerde değerlendirilmiş ve sonuçları, bu tez çalışmasında detaylı olarak verilmiştir. Test sonuçları, literatürde aynı veri setini kullanan çalışmalara göre ilk modelin %1.7'lik, ikinci modelin ise %3.64'lük bir tespit başarısı artışı elde ettiğini göstermektedir. Böylece, uzaktan algılama görüntülerindeki nesne tespitinin zorluğunu ortadan kaldıracak iki yeni nesne tespit modeli önerilmiştir.

Bilim Kodu : 92418

Anahtar Kelimeler : Nesne Tespiti, Derin Öğrenme, İnsansız Hava Aracı Görüntüleri, Evrişimli Sinir Ağları, Görüntü İşleme.

Sayfa Numarası : 78

Danışman : Prof. Dr. Necaattin BARIŞCI

DETECTION OF OBJECT IN REMOTE SENSING IMAGES USING DEEP
LEARNING

(Ph. D. Thesis)

Atakan KÖREZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2020

ABSTRACT

The object detection in the images taken from unmanned aerial vehicles, which have been frequently used in various fields such as land planning, city imaging, traffic monitoring, agriculture applications, has been receiving an increasing interest in the field of air and satellite image analysis. In this thesis, two different object detection models are proposed to detect objects in remote sensing images automatically. The first model proposed is based on the Faster Regional Convolutional Neural Network (Faster R-CNN) model structure, which has received very successful results in remote sensing images object detection. The proposed model was finalized by making improvements to increase the object detection performance of the remote sensing images. The second proposed model is a collaborative object detection model that allows three different deep learning object detection models to perform optimized coefficient weighted ensemble object detection. The effectiveness, efficiency and contribution of this proposed new models have been evaluated in the Northwestern Polytechnical University Very High Resolution 10 (NWPU-VHR10) data set consisting of remote sensing images and the results are detailed in this thesis. The test results show that according to the studies using the same data set in the literature, the first model achieved an increase in detection success of 1.7% and the second model increased by 3.64%. So, two new object detection models have been proposed that can eliminate the difficulty of object detection in remote sensing images.

Science Code : 92418

Key Words : Object Detection, Deep Learning, Unmanned Aerial Vehicle Images, Convolutional Neural Network, Image Processing.

Page Number : 78

Supervisor : Prof. Dr. Necaattin BARIŞCI

TEŐEKKÜR

Tez alıřmam sűresince engin bilgi birikiminin yanında akademik tecrűbelerini benim ile paylařarak hořgűrű ve sabırla destek olan doktora tez danıřmanım Sayın Prof. Dr. Necaattin BARIŐCI hocama,

Tez izleme komitemde olmayı kabul eden, destekleyen ve tez alıřmama deęerli katkılarını sunan Sayın Do. Dr. Aydın ETİN ve Do. Dr. Uman ERGŪN hocalarıma,

Eęitimim sűresince hep gurur duyduęum ve kendimi bir parası olarak gűrdűęum Gazi Ūniversitesi Bilgisayar Műhendislięi bűlűmű akademik ve idari alıřanlarına,

Bu sűrete hep yanımda olan, beni destekleyen, zorlu gűnlerimin dostu hayat arkadařım ve canım eřim Filiz'e,

alıřmalarım boyunca maddi manevi destekleriyle beni hibir zaman yalnız bıraktımayan aileme sonsuz teőekkűr, sevgi ve saygılarımı sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ	5
3. MATERYAL VE YÖNTEM	13
3.1. Uzaktan Algılama Görüntüleri	13
3.2. Yapay Sinir Ağları	15
3.3. Derin Öğrenme	16
3.4. Evrişimli Sinir Ağı	17
3.4.1. Evrişim işlemi	18
3.4.2. Havuzlama katmanı.....	19
3.4.3. Tam bağlı katman.....	20
3.4.4. Evrişimli sinir ağında kullanılan hiper parametreler.....	21
3.5. Ağırlık Standardizasyonu	24
3.6. Deforme Edilebilir Evrişim	26
3.7. Daha Hızlı Bölgesel Evrişimli Sinir Ağı.....	28
3.8. Özellik Piramit Ağı	29
3.9. Odaksal Kayıp	30

3.10 RetinaAđı	31
3.11. Tek Atıřlık Detektör.....	32
4. UZAKTAN ALGILAMA GÖRÜNTÜLERİNDEKİ NESNELERİN TESPİTİ.....	33
4.1. Model 1 : Geliřtirilmiř Daha Hızlı B-ESA	33
4.2. Model 2: Optimize Edilmiř Katsayı Ađırlıklı Topluluk Nesne Tespit Modeli....	37
5. ARAřTIRMA BULGULARI VE TARTIřMA.....	41
5.1. Çalıřma Ortamı ve Deđerlendirme Kriterleri.....	41
5.2. Kullanılan Veri Seti.....	42
5.3. Geliřtirilmiř Daha Hızlı B-ESA Modelini Kullanarak Farklı Eđitim – Test Veri Seti Oranları ile Yapılan Deneyler.....	45
5.4. Optimize Edilmiř Katsayı Ađırlıklı Topluluk Nesne Tespit Modeli ile Yapılan Deneyler	52
5.5. Tez Çalıřması Kapsamında Önerilen Modellerin NWPU-VHR10 Veri Seti Kullanan Çalıřmalar İle Karřılařtırılması.....	60
6. SONUÇ	65
KAYNAKLAR	69
ÖZGEÇMİř	77

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 5.1. Pozitif görüntü kümesi sınıf bazında nesne sayıları	43
Çizelge 5.2. NWPU VHR10 veri seti sınıf bazında nesne boyutları	44
Çizelge 5.3. Deney yapılan eğitim – test veri seti oranları	45
Çizelge 5.4. Farklı eğitim-test veri oranlarının model performansına etkisi	51
Çizelge 5.5. Katsayı Ağırlıklı topluluk nesne tespit modeli OHO sonuçları.....	59
Çizelge 5.6. Farklı modellerin NWPU-VHR10 veri seti üzerindeki performansı.....	60

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. 1906 yılında San Francisco şehrinde oluşan deprem sonrası çekilen hava görüntüsü.....	13
Şekil 3.2. Uzaktan algılama görüntülerinin karakteristik özellikleri	14
Şekil 3.3. Uzamsal çözünürlük çeşitleri.....	15
Şekil 3.4. Biyolojik ve yapay nöron temsili.....	15
Şekil 3.5. Yapay sinir ağı örneği.....	16
Şekil 3.6. Derin öğrenmenin başarısının temel nedenleri	17
Şekil 3.7. Evrişimsel sinir ağı örneği	18
Şekil 3.8. 5x5 boyutundaki girdiye 3x3 boyutunda filtre ile evrişim işlemi.....	19
Şekil 3.9. Havuzlama işlemi çeşitleri.....	20
Şekil 3.10. Tam bağlantılı katman yapısı.....	20
Şekil 3.11. Görüntüye piksel ekleme işleminin gösterimi	21
Şekil 3.12. Kaydırma işlemi gösterimi	22
Şekil 3.13. Yığın ve grup normalizasyonun görsel karşılaştırması	23
Şekil 3.14. Normalizasyon metodlarının karşılaştırması	25
Şekil 3.15 Deforme edilebilir evrişim yapısı	26
Şekil 3.16. Deforme edilebilir evrişim işlemi örnekleri	27
Şekil 3.17. Standard evrişim (solda), deforme edilebilir evrişim (sağda)	28
Şekil 3.18. Daha Hızlı B-ESA yapısı.....	29
Şekil 3.19 Özellik piramit ağı yapısı.....	30
Şekil 3.20 Odaksal Kayıp	31
Şekil 3.21 RetinaAğı yapısı	31
Şekil 3.22 Tek atışlık detektör yapısı.....	32
Şekil 4.1. VHR10 veri setinde yer alan nesnelerin boyut histogramı	34

Şekil	Sayfa
Şekil 4.2 Nesne tespit modeli ÖPA yapısı	35
Şekil 4.3. Geliştirilmiş Daha Hızlı B-ESA yapısı.....	36
Şekil 4.4 Katsayı Ağırlıklı Topluluk Nesne Tespit Modelinin yapısı	37
Şekil 5.1. NWPU-VHR10 veri seti örnek görüntüler	42
Şekil 5.2. Veri arttırma örnekleri.	44
Şekil 5.3. Deney 1 sonuçları	45
Şekil 5.4. Deney 2 sonuçları	46
Şekil 5.5. Deney 3 sonuçları	47
Şekil 5.6. Deney 4 sonuçları	47
Şekil 5.7. Deney 5 sonuçları	48
Şekil 5.8. Deney 6 sonuçları	48
Şekil 5.9. Deney 7 sonuçları	49
Şekil 5.10. Deney 8 sonuçları	49
Şekil 5.11. Deney 9 sonuçları	50
Şekil 5.12. Deney 10 sonuçları	52
Şekil 5.13. Deney 11 sonuçları	53
Şekil 5.14. Deney 12 sonuçları	54
Şekil 5.15. Deney 13 sonuçları	55
Şekil 5.16. Deney 14 sonuçları	56
Şekil 5.17. Deney 15 sonuçları	57
Şekil 5.18. Deney 16 sonuçları	58
Şekil 5.19. Deney 17 sonuçları	59
Şekil 5.20 Geliştirilmiş Daha Hızlı B-ESA modelinin nesne tespit sonuçları.....	63
Şekil 5.21 Katsayı Ağırlıklı Topluluk modelinin nesne tespit sonuçları	64

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AS	Ağırlık Standartlaştırma
BTA	Bölgesel Teklif Ağı
ÇL	Çakışma Listesi
DP	Doğru Pozitif
ESA	Evrışimli Sinir Ağı
GİB	Grafik İşlem Birimi
GN	Grup Normalizasyonu
HGC	Hassasiyet-Geri Çağırma Eğrisi
İBH	İlgi Bölgesi Havuzlama
MOB	Maksimum Olmayan Baskılama
NTL	Nesne Tespit Listesi
OH	Ortalama Hassasiyet
OHO	Ortalama Hassasiyetlerin Ortalaması
OKS	Ortalama Kare Sapma
ÖPA	Öznelik Piramit Ağı
SEİ	Stokastik Eğim İniş
TAD	Tek Atışlık Detektör
TL	Tespit Listesi
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağı

1. GİRİŞ

Havacılık ve uydu endüstrisindeki gelişmelere paralel olarak ortaya çıkan yüksek kapasiteli sensörler sayesinde yüksek çözünürlüklü uzaktan algılama verisi elde edilebilme süreci daha kolay hale gelmiştir. Bu durum, hem sivil hem de askeri amaçlarla, çok çeşitli ilgi alanlarında uzaktan algılama verilerinin kullanılmasına olanak sağlamıştır. Sensörlerden alınan uzaktan algılama görüntüleri; çevresel izlemede hayati bir öneme sahiptir ve şehir planlama, afet yönetimi, halk sağlığı, tarım, askeri vb. uygulamalarda kullanılmaktadır [1]. Bu uygulamalar aşağıda verilmiştir:

- Tarım alanında; ekin tipinin tespiti, ekin durum tespiti, ekin verim tespiti, yabancı otların tespiti, toprak nem durumu ölçümü,
- Şehir planlama alanında; şehirlerin genişlemesinin takibi, yerleşim alanlarının kullanım değişiminin analizi, şehir yeşil alanları izleme, hava ve su kirliliğinin izlenmesi,
- Afet yönetimi alanında; afet oluşmadan önce afet olabilecek bölgelerin tespiti, afetlerin oluşmasından sonra afet bölgesinin izlenmesi, afetten etkilenen insanların tespiti,
- Askeri uygulamalar alanında; hedef tespiti ve takibi, hava-deniz ve kara navigasyonu, stratejik ve taktiksel operasyonlar, gözetim ve keşif görevleri,
- Jeolojik uygulamalar alanında; mineral keşfi, maden tespit ve haritalama,
- Arkeolojik site alanların tespiti ve incelenmesi,
- Vahşi yaşam ve doğa koruma alanında; tropikal orman ve kıyı izleme, ekosistem analizi, kara-deniz türlerinin takibi, bio-çeşitlilik tespiti, akarsu ve göllerin tespiti ve izlenmesidir.

Uzaktan algılama uygulamaları yukarıda bahsedilen uygulama alanları ile sınırlı değildir ancak yukarıda bahsedilen uygulama alanları sıklıkla kullanılan alanlar olarak kabul görmektedir.

Kamera ve sensör teknolojisindeki gelişmeler sayesinde, akıllı telefonlar gibi mobil aygıtlar tarafından çok büyük miktarda veri üretilmektedir. Bu verinin işlenmesi, genellikle insanlar tarafından manuel olarak gerçekleştirilmektedir. Bu işlem, oldukça zaman alan zahmetli bir süreçtir. Son yıllarda ekran kartlarının performanslarının artmasına paralel olarak derin sinir ağları ile bu süreçler daha hızlı ve zahmetsiz bir hale gelmiştir. *Krizhevsky ve arkadaşlarının,*

2012 yılında gerçekleştirilen ImageNet [2] yarışmasında elde ettikleri büyük başarı, yapay zekâ alanında Derin Öğrenme tekniklerinin kullanımında büyük bir artışa neden olmuştur. Bu artış, birçok araştırmacının kendi problemlerini derin öğrenme kullanarak çözüm yoluna gitmesine sebep olmuştur. Özellikle bilgisayarlı görü alanında derin öğrenme çok popüler bir hale gelmiştir. Bu doğrultuda, son zamanlarda bilgisayarlı görü alanında yapılan bilimsel yayınların büyük çoğunluğunda derin öğrenme teknikleri kullanılmaktadır. Bu çalışmaların konu dağılımına bakıldığında, bölütleme (segmentation), sınıflandırma (classification), sahne sınıflandırma (scene classification) ve nesne tespiti (object detection) gibi konuların ağırlıklı olduğu görülmektedir.

Bölütleme, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı bölgelere (örneğin uzaktan algılama görüntüsünde yolda hareket eden araçlar ile çevreyi, yoldan ayırt edebilmek) ayırmak olarak tarif edilebilir. *Sınıflandırma*, görüntüde yer alan nesnelere görsel içeriklerine ayırma işlemidir (örneğin uzaktan algılama görüntülerinde yer alan insan, araç, ağaç, yol vb. nesnelere birbirinden ayırt edilme süreci). *Sahne sınıflandırma*, sınıflandırmadan farklı olarak görüntüyü, içinde yer alan nesnelere bütün olarak inceleyerek anlamlandırma işlemidir (örneğin uzaktan algılama görüntüsünün içerdiği deniz, gemi, liman gibi nesnelere nedeniyle deniz kategorisi olarak sınıflandırılması). *Nesne tespiti*, bir görüntüdeki nesnelere konumlarının ve özelliklerinin belirlenmesi işlemidir.

Uzaktan algılama görüntülerinin kalitesi ve ulaşılabilirliğinin artması nedeniyle araştırmacıların konuya ilgisi artmış ve literatürde uzaktan algılama nesne tespiti için derin öğrenme teknikleri sıklıkla kullanılabilir hale gelmiştir [3]. Nesne tespiti, uzaktan algılama görüntülerinin yorumlanmasında önemli rol oynar ve özellikle tarım, şehir planlama, yangın ve afet yönetimi, trafik denetimi gibi geniş bir uygulama alanına sahiptir. Bu alanlarda oldukça başarılı uygulamalar ortaya konulmuş ve her geçen gün bu sayı artarak devam etmektedir [4]. Bununla birlikte, muazzam ilerlemeler kaydedilmiş olsa bile, yüksek çözünürlüklü uzaktan algılama görüntülerinde yer alan nesnelere tespitinde hala zorluklar devam etmektedir. Bunlar;

- Görüntülerdeki nesnelere çeşitli boyutlar ve ölçülerde olması,
- Görüntülerin, aşırı detaylı yer objelerinin oluşturduğu karmaşık ve dağınık arka planlara sahip olması,
- Hava görüntülerinin elle etiketlenme sürecinin pahalı ve zahmetli olması,

- Görüntülerin elde edildiği araçların (uçak, uydu, insansız hava aracı gibi) farklı yapıda ve hızda olması nedeniyle görüntülerde oluşan kayma ve farklılıklardır.

Literatürde, yukarıda bahsedilen zorlukları aşmak için makine öğrenmesi teknikleri, özellikle derin öğrenme kullanılarak oluşturulan farklı nesne tespit modelleri içeren çalışmalar yer almaktadır. Her geçen gün yeni bir çalışma ortaya konulmaktadır ancak henüz tam olarak istenilen sonuca ulaşabilen bir model önerisi yapılamamıştır. Her çalışma, sorunları farklı bir açıdan ele alarak yeni bir çözüm öne sürmekte ve böylece konunun cazipliği artarak devam etmektedir. Bu çalışmaların özeti, tezin ikinci bölümünde verilmektedir.

Tez Çalışmasının Literatüre Katkısı

Tez çalışmasında; uzaktan algılama görüntülerindeki nesne tespiti işleminde yer alan zorlukların giderilmesine yönelik derin öğrenme kullanan iki yeni model önerilmektedir. Önerilen modeller, literatürde oldukça sık kullanılan ve uzaktan algılama görüntülerindeki nesne tespiti konusunda neredeyse standart bir veri seti haline gelmiş Northwestern Polytechnical University Very High Resolution 10 (NWPU-VHR10) [5] veri seti üzerinde detaylı deneylere tabi tutulmuştur. Deney sonuçlarına göre önerilen nesne tespit modelleri, literatürde aynı veri setini kullanan diğer çalışmalara göre daha yüksek nesne tespit başarısı elde etmiştir.

Tez çalışmasında önerilen ilk model, yüksek Grafik İşlem Birimi (GİB)(Graphic Processing Unit)(GPU) gücü gerektiren derin öğrenme modellerine istianen daha makul bir ekran kartı ile bu başarılı sonuca ulaşmıştır. Bu durum, düşük GİB gücüne sahip araştırmacıların uzaktan algılama görüntüleri gibi yüksek çözünürlüklü görüntüler üzerinde nesne tespiti çalışmaları yapabilmeleri için bir referans model olarak kullanılmasına olanak sağlamaktadır.

Tez çalışmasında önerilen ikinci modelde, üç tane farklı nesne tespit metodunun ağırlık katsayıları kullanılarak topluluk olarak nesne tespiti yapması sağlanmaktadır. Önerilen modelde kullanılan nesne tespit metotları, literatürde oldukça başarılı sonuçlar almıştır ve uzaktan algılama görüntülerinde nesne tespiti konusunda çalışan araştırmacılar tarafından

sıklıkla tercih edilmektedir. Önerilen model ise; bu metotların güçlü yanlarını birleştirerek uzaktan algılama görüntülerindeki nesnelerin tespitinde başarılı sonuçlar elde etmektedir.

Tez Çalışmasının Bölümleri

Tez çalışmasının ikinci bölümünde, uzaktan algılama görüntülerindeki nesnelerin tespiti için derin öğrenme teknikleri kullanan literatür çalışmalarının özeti yer almaktadır. Üçüncü bölümde, tez çalışması kapsamında önerilen nesne tespit modellerinin kullandığı materyal ve metotlardan bahsedilmektedir. Dördüncü bölümde, önerilen modeller detaylı olarak açıklanmaktadır. Beşinci bölümde, önerilen modellerin performansını ölçmek için yapılan deneyler ve modellerin, literatürde NWPU-VHR10 veri setini kullanan diğer çalışmalar ile karşılaştırması yer almaktadır. Son olarak altıncı bölümde, yapılan deneyler temel alınarak hazırlanan tezin sonuç kısmı yer almaktadır.

2. LİTERATÜR ÖZETİ

Son zamanlarda uzaktan algılama veri toplama teknolojilerindeki ve makine öğrenmesindeki, özellikle derin öğrenmedeki gelişmeler sayesinde, uzaktan algılama görüntülerindeki nesnelere tespiti konusunda sayısız çalışma yapılmıştır. Bu doğrultuda, bu bölümde uzaktan algılama görüntülerinde yer alan nesnelere tespiti için derin öğrenme kullanılarak yapılan bu çalışmalar özetlenmektedir. İlk olarak konu ile ilgili makale ve bildiriler, bölümün sonuna doğru ise tezlerden bahsedilmektedir.

Jin ve arkadaşları, uydu görüntüleme için vektör rehberli bir araç tespit yöntemi önermektedirler [6]. Yöntemleri, görüntüdeki pikselleri araç ve araç dışı sınıflandıran mekânsal ve spektral özellikleri içeren derin bir sinir ağıdır. *Chen ve arkadaşları*, uzaktan algılama görüntülerinde araç tespiti için Evrişimli Sinir Ağı (ESA) (Convolutional Neural Network)(CNN)nın son evrişim ve havuzlama katmanını çok değişkenli bloklara ayıran hibrit bir derin ESA modeli önermektedir [7]. Önerdikleri hibrit modelde, uzaktan algılama görüntülerindeki nesnelere büyük ölçekli varyans problemini çözmek için görüntülerin çoklu ölçek özneliklerinden yararlanmışlardır. *Jiang ve arkadaşlarının* yaptığı çalışmada, uzaktan algılama görüntüleri grafik tabanlı süper piksel segmentasyonu kullanılarak birden fazla bölgeye ayrılmaktadır [8]. Ardından bu bölgelerin araç içerip içermediğini tespit etmek için ESA tabanlı bir nesne tespit ağı önermişlerdir.

Transfer öğrenimi, bir görev için geliştirilen bir modelin ikinci bir görevdeki bir model için başlangıç noktası olarak yeniden kullanıldığı bir makine öğrenme yöntemidir. *Zhou ve arkadaşları*, uzaktan algılama görüntülerindeki nesnelere tespiti için zayıf denetimli (weakly supervised) bir nesne tespit yöntemi önermektedir [9]. Önerdikleri nesne tespit modelinin hızlı eğitilmesi için negatif önyükleme şeması ve transfer öğrenmesinden faydalanmışlardır. *Zhang ve arkadaşları*, yerel özelliklere odaklanmış bir yönlendirilmiş gradyanların histogramı [10] ile önceden eğitilmiş ESA modelinden transfer öğrenmesi tekniği ile elde edilen ağırlıkları birleştiren hiyerarşik yapıya sahip bir uzaktan algılama nesne tespit modeli önermektedir [11]. Modelleri, uzaktan algılama görüntülerinde yer alan yağ tankı nesnelere tespit etmektedir. Ayrıca, görüntüler, ön işlem olarak elips ve çizgi segmenti işleminden geçerler. *Salberg*, hava görüntülerindeki fokların otomatik tespiti için önceden eğitilmiş AlexNet[12] modelinin öznelik çıkarma yöntemini geliştirerek yeni bir model

önermektedir [13]. *Sevo ve arkadaşları*, nesnelerin yönelim değişimleri sorununu çözmek için iki aşamalı ESA eğitimine tabi tutulan bir model önermektedirler [14]. İki aşamalı eğitimde ilk olarak GoogLeNet[15], UC-Merced veri setinde[16] ince ayar yapılarak eğitilmektedir. Ardından eğitilmiş modelin ağırlıklarını başlangıç ağırlığı olarak kullanan model, uzaktan algılama görüntülerindeki nesnelere kayar pencere yöntemiyle tespit etmesi için bir kez daha bağımsız olarak eğitime tabi tutulmaktadır. *Zhu ve arkadaşlarının* yaptığı çalışmada, birleştirilmiş katmanlardan çıkarılan önceden eğitilmiş ESA özelliklerini kullanarak kaba bir yerelleştirme çerçevesinde yönlendirmeye dayanıklı nesne algılama işlemi gerçekleştirilmiştir [17].

Zhang ve arkadaşları, orijinal görüntüden eğitim verilerini otomatik olarak incelemek için insan emeğini önemli ölçüde azaltabilecek bir model önermektedir [18]. Çalışmada, yüksek çözünürlüklü uzaktan algılama görüntülerindeki uçak nesnelerinin tespiti için, aday bölge teklif açısından oluşan çift ESA kullanan zayıf denetimli bir nesne tespit ağı ortaya konulmuştur. *Peicheng ve arkadaşlarının* yaptığı çalışmada, nesne tespit performansını artırmak için yeni ve etkili bir yaklaşım olan Rotasyon-Değişmez ESA modeli önerilmektedir [19]. Çalışmalarında, önceden eğitilmiş AlexNet modeline yeni bir döndürme-değişmez katman eklemektedirler. Böylece standart ESA ağına, hava görüntülerindeki çok-yönlü nesnelere tespit başarısını arttırmışlardır.

Wang ve arkadaşlarının yaptığı çalışmada, tam boyutlu bir uzaktan algılama görüntüsünden çok ölçekli özellikleri ayıklamak için atlama bağlantılı enkoder-kod çözücü model önerilmektedir [20]. Ayrıca çalışmalarında, dikkat, sınıflandırma ve regresyon kayıplarının toplamı olan yeni bir hibrit kayıp fonksiyonu ortaya konulmuştur. *Long ve arkadaşları*, yüksek çözünürlüklü uzaktan algılama görüntülerinde algılanan nesnelerin otomatik olarak doğru konumlandırılması sorununu ele almışlardır [21]. Bu sorunun çözümü için 3 aşamalı (bölge teklifi, sınıflandırma ve nesnelerin doğru olarak yerleştirilmesi) bir nesne tespit metodu öneriyorlar. Ayrıca çalışmalarında, nesne tahmin konum doğruluğunu arttırmaya yönelik denetimsiz bir skor tabanlı sınırlama kutusu regresyonu algoritması önermişlerdir. *Li ve arkadaşının* yaptığı çalışmada, uzaktan algılama görüntülerindeki nesnelerin tespiti maksadıyla daha az aday bölge önerebilmek için; görüntülerde, büyük alanlardan daha küçük alanlara doğru nesne tespiti yapan bir model önermişlerdir [22]. Önerdikleri metotta, ilk olarak nesne içerebilecek büyük aday bölgeler seçilir ardından da küçük aday bölgeler büyük aday bölgelerden kırılır ve nesne veya arka plan olarak sınıflandırılır.

ElMikaty ve Stathaki yaptıkları çalışmada, kayar pencere yapısı geliştirilerek yeni bir kayar pencere yapısı ortaya konulmuştur [23]. Bu yeni yapı, pencere değerlendirme, özelliklerin çıkarılması ve kodlanması, sınıflandırma ve önışlem olmak üzere dört aşamadan oluşur. Böylece uzaktan algılama görüntülerindeki küçük nesnelere tespit başarısı artırılmaktadır. *Lin ve arkadaşlarının* yaptıkları çalışmada, uzaktan algılama görüntülerindeki gemilerin tespiti üzerine bir ağ modeli önerilmektedir [24]. Önerdikleri ağda, farklı derinliklerde katmanlara farklı görevler atayan bir görev bölümlenme modeli uygulanmaktadır. Ağdaki derin katman, algılama işlevselliği sağlarken sığ katman ise lokalizasyon işlevini yerine getirir. *Wu ve arkadaşları*, Fourier Tabanlı Dönme-Değişmez Öznitelik Arttırıcı özelliğini kullanarak uzaktan algılama nesnelere tespit etmeye çalışmışlardır [25]. Fourier tabanlı dönme-değişmez özelliği, ilk olarak kutupsal koordinatta oluşturulur. Daha sonra, çıkarılan özellikler, toplam kanal özellikleri kullanılarak yapısal olarak geliştirilir. Böylece, model, daha hızlı bir öznitelik hesaplaması yeteneğine sahip olur.

Dong ve arkadaşlarının yaptığı çalışmada, yeni bir maksimum olmayan baskılama(MOB)(Non-Maximum Supression)(NMS) yöntemi önerilmekte (Sig-MOB) ve önerdikleri yeni Sig-MOB'u kullanarak Daha Hızlı Bölgesel Evrişimli Sinir Ağı (Daha Hızlı B-ESA)(Faster Regional Convolutional Neural Network)(Faster R-CNN) [26]'nı transfer öğrenimi ile birleştiren bir yaklaşım önerilmektedir [27]. Sig-MOB, bölge teklif ağı aşamasında geleneksel MOB'un yerini alır ve küçük hedeflerin tespitinde başarı oranını yükseltir. *Gong ve arkadaşları* yaptıkları çalışmada, nesne oluşturma için teklif oluşturma, içerik özelliği çıkarma, özellik birleştirme ve sınıflandırma içeren içeriğe duyarlı evrişimli sinir ağı modeli önermektedirler [28]. Önerdikleri ağı kullanarak özellik temsilini zenginleştiren ve nesnelere arasındaki temel bağlam bilgisini benimseyen bir nesne tespit modeli ortaya koymuşlardır. *Cheng ve arkadaşları*, geleneksel ileri beslemeli ağa dayalı yukarıdan aşağı geri bildirim mekanizmasını kullanan çok sınıflı nesnelere algılama geri bildirim ağı önermiştir [29]. *Wang ve arkadaşları*, bağlam bilgilerini hem birden çok ölçekte hem de aynı ölçek özellik haritalarında toplayan birleştirilmiş bir model kullanarak uzaktan algılama görüntülerinde nesne tespiti yapmışlardır [30]. Çalışmada ortaya konulan model, her kanalın belirli bir dönme yönünü ifade ettiği ve aynı ağırlıkları paylaştığı birden fazla ESA içerir.

Li ve arkadaşlarının yaptıkları çalışmada, iki bağımsız yol boyunca yerel ve bağlamsal

özellikleri öğrenebilen çift kanallı bir özellik füzyon ağı önerilmektedir [31]. Önerdikleri modelde, bahse konu bu iki tür özellik uzaktan algılama görüntülerindeki nesnelere güçlü bir ortak temsili oluşturmak için son işlem katmanlarında birleştirilir. *Wang ve arkadaşlarının* yaptıkları çalışmada, çapa içermeyen ve kayan penceresiz ters evrişim bölge teklif ağı önermektedirler ve bu bölge teklif ağını kullanarak iki aşamalı bir nesne tespit ağı oluşturmuşlardır [32]. *Deng ve arkadaşlarının* yaptığı çalışmada, uzaktan algılama görüntülerindeki araçları tespit etmek için hızlı ve doğru bir nesne tespit modeli önerilmektedir [33]. Önerdikleri modelde, araç benzeri hedefleri doğru bir şekilde çıkarmak için, hiyerarşik öznitelik haritalarının birleşimi olan hiper özellik haritasına dayanan bir araç teklif ağı geliştirmişlerdir. *Zhang ve Zhang* yaptığı çalışmada, yüksek çözünürlüklü uzaktan algılama görüntüleri için iki katmanlı görsel çıkıntı analiz modeline ve destek vektör makinelerine dayanan yeni bir havaalanı ve uçak tespit yöntemi önerilmektedir [34].

Chaudhuri ve arkadaşları, yüksek çözünürlüklü uzaktan algılama görüntülerinde güvenilir ve doğru bina tespiti için yeni bir model önermektedir [35]. Önerilen model, görüntüdeki nesnelere doğası, optik etkileşimleri ve ortaya çıkan görüntü üzerindeki etkileri hakkında alan bilgisini (mekansal ve spektral özellikler) kullanır. *Han ve arkadaşlarının* yaptığı çalışmada, uzaktan algılama görüntülerindeki nesnelere tespiti için Daha Hızlı B-ESA modelinin geliştirilmiş bir biçimi önerilmektedir [36]. Çalışmada yapılan geliştirme, Daha Hızlı B-ESA'nın bölge teklifi oluşturma aşaması ile nesne algılama aşaması arasında özniteliklerin paylaşılmasıdır. Önerdikleri modelin nesne tespit verimliliğini arttırmak için transfer öğrenmesinden faydalanmışlardır. *Chen ve arkadaşları*, en alt katmandaki özniteliklerin elde edilmesi için semantik bölütleme duyarlı ESA modeli önermektedir [37]. Böylece üst katmanlardaki öznitelikler ile zenginleştirilmiş bir öznitelik haritası elde edilmektedir. Daha sonra bu harita Tek Atışlık Detektör (TAD)(Single Shot Multibox Detector)(SSD) [38] modeline verilerek nesne tespiti yapılmaktadır.

Liu ve arkadaşlarının yaptığı çalışmada, uzaktan algılama görüntülerindeki farklı ölçek ve uzaysal çözünürlükteki bina nesnelere özniteliklerinden yararlanarak nesne tespiti yapmak için Gaussian piramit tekniğini kullanarak çok seviyeli bir model ortaya koymaktadırlar [39]. Ardından evrişimli sinir ağı kullanılarak çok katmanlı bina nesnesi tespiti gerçekleştirilmektedir. *Körez ve Barışçı* tarafından gerçekleştirilen çalışmada ise, uzaktan algılama görüntülerindeki nesnelere tespiti için düşük kapasiteli ekran kartlarında eğitim yapılabilecek bir model önermektedirler [40]. Önerdikleri model Daha Hızlı B-ESA

modelini esas almakta, ağırlık standartlaşma tekniği ve ters evrişimli sinir ağı kullanılarak mevcut model düşük işlem gücü ile yüksek performans elde etmiştir.

Barut, yaptığı tez çalışmasında, uydulardan alınan uzaktan algılama görüntülerini kullanarak kara kullanım analizi ve mekânsal nesne tespit analizi yapmıştır [41]. Yazar, analiz çalışmasında derin öğrenme temel yapısı olan ESA'yı kullanmıştır. *Zakharova*, tez çalışmasında, derin öğrenme teknikleri kullanarak uzaktan algılama görüntülerindeki Hindistan cevizi ağaçlarının tespiti ve sayımı yapan bir model önermektedir [42]. Çalışmada, 10000 * 10000 piksel görüntüler üzerinde 100*100 boyutlarında kayar çerçeve kullanılmış ve görüntü parçalara ayrılmıştır. Ayrıca, modelinin eğitim süresini kısaltmak için transfer öğrenmesinden faydalanılmıştır. *Chapman*, uzaktan algılama görüntülerindeki gemi, uçak veya benzeri platformların bölgesel tespiti ve sınıflandırılması için derin öğrenme tekniğinin optimize edilip edilemeyeceğini incelemektedir [43]. Çalışmada, Daha Hızlı B-ESA modelinin bölge önerme ağına yeni adaptasyonlar yapılarak performans değerlendirmesi yapılmıştır.

Son yıllarda uzaktan algılama görüntülerindeki nesne tespitinde, topluluk modellerinin kullanıldığı çalışmaların da öne çıktığı görülmektedir. *Zhong ve Wang*'ın yaptığı çalışmada, uzaktan algılama görüntülerindeki şehir bölgelerinin tespiti için birden fazla koşulsal rastgele alanlar [44] birleştirilerek yeni bir topluluk nesne tespit modeli ortaya konulmaktadır [45]. *Gokaraju ve arkadaşları*, uzaktan algılama görüntülerinden zararlı algı çirçesinin tespiti için uzamsal ve zamansal görüntüleri makine öğrenmesi teknikleri ile birleştiren bir topluluk nesne tespit modeli önermektedir [46]. *Roy ve arkadaşlarının* yaptığı çalışmada, uzaktan algılama görüntülerindeki değişimleri tespit etmek için, birden fazla farklı mimariye sahip çok katmanlı algılayıcıyı topluluk olarak kullanmaktadır [47]. Böylece yapay sinir ağlarının bir türü olan çok katmanlı algılayıcılar için optimum mimari seçme sorunu da önlenmektedir. *Yu ve Liu*, farklı alıcı alanlarına sahip üç ESA'yı kullanarak uzaktan algılama görüntüleri için topluluk sahne sınıflandırma modeli önermektedir [48]. Söz konusu 3 ESA, farklı katmanlardaki verileri kullanarak daha başarılı bir sınıflandırma yapmaktadır. Dede ve arkadaşlarının yaptığı çalışmada, uzaktan algılama görüntü sahne sınıflandırılması için YoğunAğ (DenseNet) [49] ve Başlangıç(Inception) [50] ağlarının son evrişim katmanları, homojen, heterojen ve anlık görüntü olarak topluluk işlemine tabi tutulmaktadır [51]. *Jiang ve arkadaşları*, uzaktan algılama görüntüleri kullanılarak elektrik direklerindeki izolatörlerin arıza tespiti için topluluk tabanlı bir model önermektedir [52].

Model, düşük, orta ve yüksek seviyeli üç çok katmanlı algılayıcı birleştiren bir topluluk mimarisi olarak tanımlanmaktadır.

Bouska, uzaktan algılama görüntüleri ile ilgili literatürde yapılan çalışmalarda genellikle araba, uçak, gemi gibi büyük nesnelerin tespitinin yapıldığı ancak insan gibi küçük ve çok sayıda nesnenin tespitinin zor olduğunu belirtmiştir [53]. Bu doğrultuda tez çalışmasında, uzaktan algılama görüntülerinde insan tespiti ve sayılması ile ilgili mevcut algoritmaları (Daha Hızlı B-ESA ve Retina Ağı(RetinaNet)) kullanarak yapmış olduğu deney ve sonuçlarından bahsetmektedir. *Chianucci'nin* yaptığı tez çalışmasında, hava görüntülerindeki nesnelerin tespiti için uzamsal dönüşüm ağının yarı-denetimli ve tam-denetimli olarak eğitilmesi ile elde edilen iki farklı ağ yaklaşımından bahsedilmektedir [54]. Tezin sonuç kısmında ise bu iki ağın birbiri ile karşılaştırması yapılmaktadır. *Lian*, yaptığı tez çalışmasında, hem hiper - spektral görüntüler hem de yüksek çözünürlüklü hava görüntüleri için nesne tespit algoritmaları araştırılarak uzaktan algılama uygulamalarında nesne algılama sorunlarını incelemektedir [55]. Çalışmadaki nesne tespit algoritmaları; görüntü bölütleme ile tespit yönteminin entegre edildiği eşleştirme filtreleri, ağaç-eşleşme tabanlı nesne tespit yapısı ve evrişimli sinir ağının kullanıldığı nesne tespit modelidir. *Bhat* yaptığı tez çalışmasında, yeni bir nesne çapa kutusu önermektedir [56]. Bu çapa kutusu, standart çapa kutusunun yükseklik ve genişlik değerlerine açısal anlam katarak 45 derecelik bir dönme eksenini etrafında yer alan nesnelere modellemek için kullanılmaktadır.

Sümbül yaptığı tez çalışmasında, farklı kaynaklardan elde edilen görüntüleri aynı anda karşılaştıran ve sınıflandıran bir sinir ağı önermektedir [57]. Bu işlem, bir görüntünün kaynak olarak kabul edilmesi ve bu görüntünün veri setindeki diğer görüntülerdeki olası nesne içeren bölgelerin ağırlık temsili ile karşılaştırılarak nesne tespiti yapılmasıdır. *Soydaş*, yaptığı tez çalışmasında, uydu görüntülerinden uçak tespiti konusunu incelemektedir [58]. Geleneksel yöntemler ile derin öğrenme tekniğine dayalı farklı sinir ağı mimarilerini eğitmiş ve test etmiştir. Ayrıca, büyük ölçekli görüntülerde hızlı tespit ve yüksek başarımlar için bir algoritma geliştirmiş, farklı mimarilerin kullanımı ve eğitim yöntemlerinin başarımlarına etkilerini incelemiştir. *Önün'ün* yaptığı çalışmada ise büyük boyutlu hava görüntülerinin işlenebilir resim boyutuna gelmesi için bölümlenerek işlenmesi ve veri seti elde edilmesi sağlanmıştır [59]. Hazırlanan bu veri seti eğitilerek daha sonra test amaçlı ayrılan verilerin Derin Öğrenme U-Net ağ modeli ile istenilen yolların tespiti gerçekleştirilmiştir. Ayrıca çalışmada, Türkiye için derin öğrenme çalışmalarında kullanılacak veri seti oluşturma

yöntemleri sunulmuştur.

Uslu'nun yaptığı tez çalışmasında, tek sınıf sınıflandırıcılarını topluluk öğrenme yöntemleri ile kullanarak hiper-spektral görüntü sınıflandırma ve hedef tespiti işlemlerinin gerçekleştirilmesi amaçlanmaktadır [60]. Ayrıca tez çalışmasında, ortaya koyulan yöntemlerle az örnek verisi koşullarında Hughes Etkisini [61] ortadan kaldıracak iyi sonuçların alınması için öneriler verilmektedir. *Yılmaz'ın* yaptığı tez çalışmasında, İngilizce bir metin içeriğindeki neşe, korku, öfke, üzüntü, tiksinti ve şaşkınlık duygularının otomatik olarak sınıflandırılmasında Topluluk Öğrenmesi yöntemlerinin etkileri ölçülmüştür [62]. *Ergül'ün* yaptığı tez çalışmasında ise; uzaktan algılama görüntülerindeki nesnelerin sınıflandırılması için, çoklu örnek öğrenme, çoklu sınıflayıcı sistemler ve çekirdek yöntemleri birleştirilerek topluluk sınıflandırıcı olarak kullanılmaktadır [63].




3. MATERYAL VE YÖNTEM

Bu bölümde, tez çalışmasının sonucu olarak ortaya konulan uzaktan algılama nesne tespit modeli oluştururken kullanılan yapılar ve kavramlar açıklanmaktadır.

3.1. Uzaktan Algılama Görüntüleri


Çevresel değişimin insan ve ekolojik kaynaklı etkilerinin bilinmesi, sürdürülebilir ve sürekli ekonomik - sosyal kalkınma için kritik öneme sahiptir. Son 50 yılda daha ayrıntılı uzaktan algılama görüntüleri elde edildikçe çevresel değişimin tanımlanması ve izlenmesi daha etkili hale gelmiştir. Bu tür görüntüler, hem fotoğrafik hem de dijital olarak küresel çevredeki doğal ve insan kaynaklı değişikliklerin izlenmesini ve analizini sağlamaktadır. İlk uzaktan algılama görüntüsü, bir balon yardımıyla 150 yıl önce elde edilmiştir. Bu görüntüden yaklaşık 50 yıl sonra uçurtmaya asılı bir kameradan çekilen fotoğraf ile 1906 yılı San Francisco depreminin etkileri belgelenmiştir (Şekil 3.1). 1940'ların başından itibaren gerçekleştirilen deneysel roket fırlatmaları sırasında çekilen dünya atmosferinin fotoğrafları, bilim insanlarının hava durumunu izlemeyi ve tüm Dünya'yı uydulardan haritalamayı sağlamaktadır.



Şekil 3.1. 1906 yılında San Francisco şehrinde oluşan deprem sonrası çekilen hava görüntüsü

Uzaktan algılama görüntüleri, Şekil 3.2'de görüleceği üzere spektral (spectral), uzamsal (spatial), radyometrik (radiometric) ve zamansal (temporal) çözünürlükler ile karakterize edilir [64]. Spektral çözünürlük, sensörün sahne hakkında bilgi topladığı bant genişliği ve örnekleme oranını ifade eder. Yüksek spektral çözünürlük, dar bir bant genişliği (örneğin,

10 nm) ile karakterize edilir. Uzamsal çözünürlük, sahnede ayrılabilen en küçük özellikleri ifade eder. Radyometrik çözünürlük, sensörün kaydedebileceği dinamik aralığı veya toplam olarak birbirinden farklı sinyal sayısını ifade eder. Zamansal çözünürlük ise, sensör tarafından alınan ardışık görüntüler arasındaki geçen süreyi ifade etmektedir.



Şekil 3.2. Uzaktan algılama görüntülerinin karakteristik özellikleri

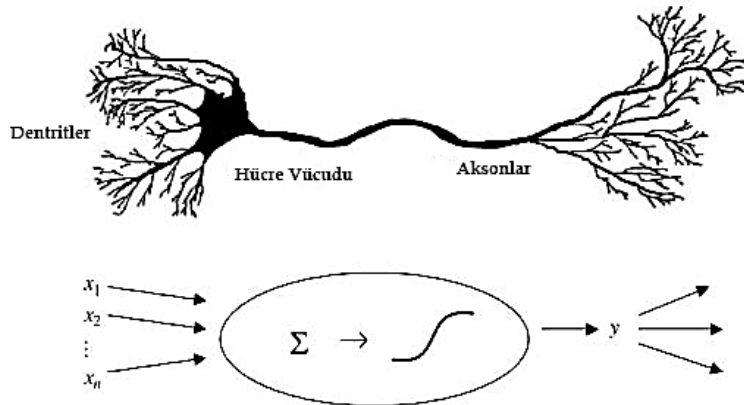
Tez çalışmasında, Şekil 3.2’de görülen uzaktan algılama karakteristiklerinden uzamsal karakteristik ele alınmıştır. Uzamsal görüntüler, uzaktan algılama görüntüsünün piksel cinsinden ayrıntıdır. Daha yüksek uzamsal çözünürlük daha fazla ayrıntı ve daha küçük piksel boyutu anlamına gelirken, daha düşük uzamsal çözünürlük daha az ayrıntı ve daha büyük piksel boyutu anlamına gelmektedir (Şekil 3.3).



Şekil 3.3. Uzamsal çözünürlük çeşitleri

3.2. Yapay Sinir Ağları


Yapay Sinir Ağı (YSA)(Artificial Neural Network), insan beynine benzer şekilde çalışan bir bilgisayar programıdır. Yapay Sinir Ağlarının amacı, beynimizin problem çözme ve öğrenme gibi yapabileceği bilişsel işlevleri yerine getirmektir. YSA'ların öğrenme özelliği sayesinde geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmektedirler. Yine öğrenme yeteneği sayesinde, bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir.



Şekil 3.4. Biyolojik ve yapay nöron temsili

YSA'lar, 1900'lerden bu yana yapay zekânın alt kolu olarak araştırmacılar tarafından oldukça sık olarak kullanılmaktadır. 1970'li yıllardan sonra bu alanda artan bir şekilde önemli çalışmalar yapılmıştır. İnsan beyninin hesaplama yeteneğinden etkilenerek tasarlanan ilk yapay sinir ağı, W. McCulloch ve W.Pitts tarafından 1943 yılında ortaya konulmuştur. Günümüzde YSA'lar, mühendislik alanına, tıp bilimi, finansal konular, arıza

tespit ve analizi, endüstri alanında, askeri alanda vb. birçok alanda kullanılmaktadır. YSA'larda girişteki nöronlar giriş katmanını, ortadaki nöronlar gizli katman/katmanları ve sondaki nöronlar da çıkış katmanını oluşturur. Önceki katman ile bir sonraki katmandaki her nöron arasında bağlantılar vardır. Bu bağlantılar ağırlık matrislerini temsil eder. Gizli katmanların sayısı ve katmanlardaki hücre sayısı, yapılacak işlemin karmaşıklığına göre değişir.



Şekil 3.5. Yapay sinir ağı örneği

3.3. Derin Öğrenme

Derin Öğrenme algoritmaları, YSA'ların yapısal olarak daha karmaşık hali olarak düşünülebilir. YSA algoritmaları insandaki öğrenme işleyişinden hareketle geliştirilmiştir. Biyolojik sinir sisteminde bulunan nöronların birbirleri ile ilişki kurması gibi YSA sistemlerinde de nöron şeklinde tanımlanan yapılar birbirleri ile bağlantılı olacak şekilde modellenmişlerdir. Algoritma bu şekilde; öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahip olmaktadır.

Derin Öğrenme algoritmalarının makine öğrenmesindeki var olan algoritmalarından ayrılan yönü; çok yüksek miktarda veriye ve karmaşık yapısı ile de bu yüksek veriyi işleyebilecek çok yüksek hesaplama gücü olan donanımlara ihtiyaç duymasındadır. Son yıllarda özellikle görüntü işleme alanında etiketli veri sayısı milyon mertebelerini geçmiştir. Ekran kartı temelli hesaplama gücü alanındaki büyük ilerlemelerin de etkisiyle Derin Öğrenme algoritmaları çok popüler olmuştur. Derin Öğrenme yöntemleri ile birçok alanda bilinen en iyi başarı düzeyleri (State of the art) çok daha yukarılara çıkmıştır. Özellikle, büyük miktarlarda etiketlenmiş eğitim verilerinden özellik saptama yapabilen sistemler oluşturmak


için ileri teknoloji, çok seviyeli “derin” sinir ağların kullanılması olan Derin Öğrenme, önemli derecede yatırım ve araştırmanın yapıldığı bir alandır. Yüksek veri ve hesaplama gücü olanaklarına sahip büyük teknoloji firmaları (Google, Facebook, Microsoft, Nvidia vb.) tarafından da kullanılıp ürünlerine entegre edilmektedir. Aynı zamanda bu teknoloji firmaları kendi Derin Öğrenme yazılım kütüphanelerini geliştirici topluluklara da açarak bu alandaki hızlı ilerlemeye destek olmaktadır.



Şekil 3.6. Derin öğrenmenin başarısının temel nedenleri

3.4. Evrişimli Sinir Ağı (ESA)

Bir diğer derin öğrenme mimarisi olan Evrişimli Sinir Ağları, özellikle ayırım yapmak amacıyla kullanılmaktadır. Biyolojiden ilham alınarak üretilen çok katmanlı algılayıcıların bir türevidirler [65]. Evrişimsel sinir ağları, eğitilebilen birçok katmandan oluşmaktadır. Her katmanın kendi içinde öznitelik havuzlama katmanı, filtre katmanı ve doğrusal olmayan katman olmak üzere üç katmanı vardır. Filtre katmanında değişik öznitelik çıkarılması işine yarayan birçok çekirdek bulunmaktadır. Havuzlama katmanında, elde edilen her öznitelik haritası ayrı ayrı ele alınır. Her harita komşu değerinin ortalaması veya maksimum değerinin elde edilmesini sağlamaktadır. ESA algoritmaları görüntü ve ses işleme alanı başta olmak üzere doğal dil işleme, biyomedikal gibi birçok farklı alanda uygulanmaktadır. Özellikle görüntü işleme alanında oldukça başarılı sonuçlar elde edilmiştir. MNIST veri kümesi üzerinde, *Ciregan* yaptığı çalışmada, ESA ile hata oranını %2'lere kadar düşürmeyi başarmıştır [66].



Şekil 3.7. Evrişimsel sinir ağı örneği


ESA yapısını oluşturan temel yapıların ne olduğu ve kısaca açıklaması bölümün devamında verilmektedir.

3.4.1. Evrişim işlemi

Verilen $f(t)$ ve $g(t)$ fonksiyonlarının örtüşme miktarını gösteren, $f(s)g(t-s)$ ifadesinin tüm zaman eksenini boyunca tümlevi olarak hesaplanan ve doğrusal sistemlerde, çıkış sinyalinin belirlenmesi için, girdi sinyali ile sistem tepki fonksiyonunu arasında uygulanan işleme evrişim denmektedir. Evrişim işleminin amacı, girdi verisinden öznitelik çıkarmaktır. ESA yapısında evrişim işlemi, filtre olarak görev yapan çekirdek (kernel) fonksiyonunun görüntü üzerinde belirli bir düzen ile kaydırılarak gezdirilmesidir. Tüm görüntünün üzerinde filtrenin kaydırılarak gezdirilmesi neticesinde görüntünün öznitelik haritası elde edilir. Görüntü f , g çekirdek fonksiyonu olmak üzere evrişim işleminin eşitliği 3.1'de verilmiştir.

$$f * g = \sum_k \sum_l f(i, j) g(i - k, j - l) \quad (3.1)$$


Eşitlik 3.1'de f ve g ifadeleri, evrişim işlemi sonucunda elde edilen matrisin konumlarını ifade eder. Şekil 3.8'de 5x5 boyutundaki bir girdiye 3x3 boyutunda filtre ile evrişim işleminin uygulanması görülmektedir.



Şekil 3.8. 5x5 boyutundaki girdiye 3x3 boyutunda filtre ile evrişim işlemi

3.4.2. Havuzlama katmanı


Evrişimli sinir ağındaki parametrelerin ve hesaplamaların azaltılması amacıyla evrişim katmanı çıktısı boyutunun azaltılması işlemine havuzlama denilmektedir. Havuzlama katmanının temel görevi alt örnekleme (subsampling) yapmaktır. Yapılan bu işlem ağın derinlik boyutunu etkilemezken görüntü boyutunda azalmaya sebep olur. Bu azalma, bilgi kaybına neden olmasına rağmen ağın ezberlemesini engellemek için yapılmış faydalı bir işlemdir. Havuzlama katmanı, genellikle evrişim katmanlarından sonra kullanılır. Bazı durumlarda ESA'nın çıkış kısmı olan tam bağlı katmanlar arasında da havuzlama katmanı kullanılabilir. Havuzlama katmanında, havuz boyutu ve adım (stride) değeri olmak üzere 2 parametre vardır. Ayrıca, görüntüyü oluşturan piksellerin maksimum değeri (max pooling) veya ortalaması (average pooling) alınarak hesaplanan 2 tür havuzlama işlemi de vardır (Şekil 3.9).



Şekil 3.9. Havuzlama işlemi çeşitleri

3.4.3. Tam bağlı katman

Tam bağlı katman, bir katmandaki her nöronu başka bir katmandaki her nörona bağlar. Prensipte geleneksel çok katmanlı algılayıcı sinir ağı ile aynıdır. Evrişim ve havuzlama işlemleri sonucunda üretilen matrissel değerler, bu katman tarafından girdi olarak alınır ve çıkış olarak vektörsel bir sonuç üretilir (Şekil 3.10).

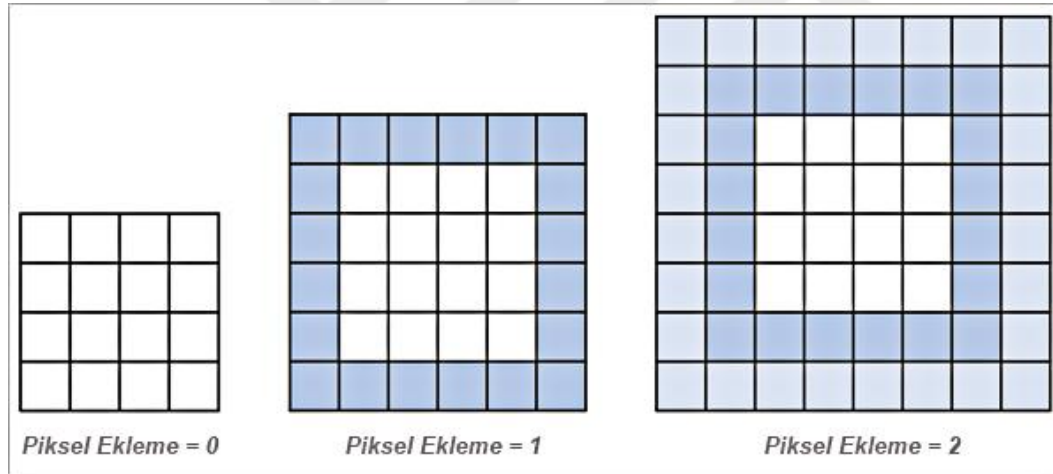


Şekil 3.10. Tam bağlantılı katman yapısı

3.4.4. Evrişimli sinir ağında kullanılan hiper parametreler

Derin öğrenme modelleri oluşturma aşamasında, bazı parametreler sabit kalırken bazı parametrelerin türü ve değerleri tamamen tasarımcıya bağlıdır. Hiper parametreler, modelin başarısını büyük ölçüde etkileyen ve kullanıcı kontrollü parametrelere denir. Bu kısımda derin öğrenmede sıklıkla kullanılan ve tez çalışmasında kontrollü olarak değiştirdiğimiz parametreler aşağıda kısaca açıklanmaktadır.

- **Piksel ekleme** : Görüntünün etrafına ekstra piksel ekleme işlemine denir. Bu işlemin amacı, evrişim işleminden sonra giriş işareti ile çıkış işareti arasındaki boyut farkını ortadan kaldırmaktır. Piksel ekleme işleminde ekstra eklenecek pikseller genellikle sıfır veya kenar pikselliyle aynı değer olarak seçilir. Örnek bir piksel ekleme işlemi şekil 3.11’de görülmektedir.




Şekil 3.11. Görüntüye piksel ekleme işleminin gösterimi

- **Kaydırma** : Evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde ne kadar piksellik adımlarla kaydıracağını bilgidir. Bu da onu doğrudan çıkış boyutunu etkileyen diğer bir parametre haline getirmektedir (Şekil 3.12).
- **Yığın Normalizasyonu** : Yığın Normalizasyonu, yapay sinir ağlarının hızını, performansını ve kararlılığını geliştirmek için kullanılan bir tekniktir [54]. Genellikle, bir sinir ağını eğitmek için, giriş verilerine bazı ön işlemler yapılır. Örneğin, tüm veriler normal bir dağılıma benzeyecek şekilde normalleştirilebilir (yani sıfır ortalama ve ya birimsel varyans işlemi). Bu ön işlem; sigmoid işlevi gibi doğrusal olmayan aktivasyon

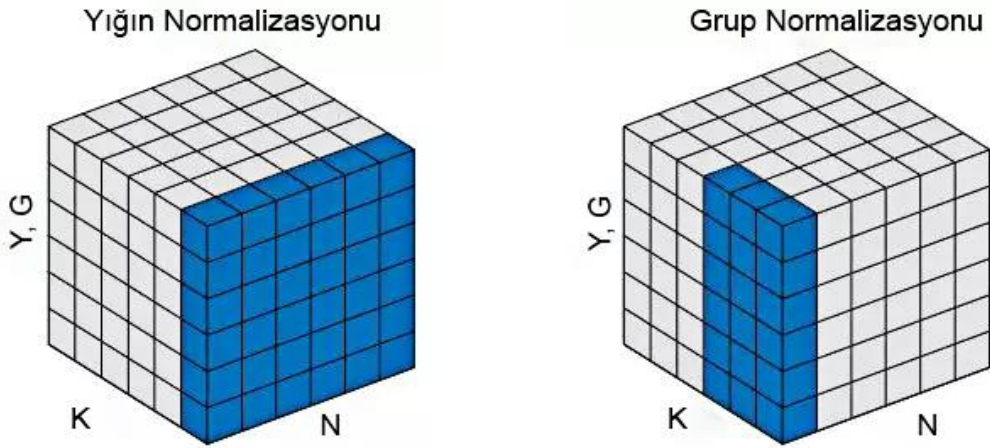
fonksiyonlarının erken doygunluğunu önlemek, tüm giriş verilerinin aynı değer aralığında olmasını sağlamak vb. nedenlerden ötürü sinir ağları için vazgeçilmezdir. Ancak sorun ara katmanlarda ortaya çıkmaktadır. Çünkü aktivasyonların dağılımı eğitim sırasında sürekli değişir. Bu durumda da her katmanın, eğitim adımlarında yeni bir dağılıma kayma eğilimi, toplam eğitim sürecini yavaşlatır. Bu sorun iç değişken kayması (covariate shift) olarak bilinir. Bu sorunun çözümü için, her katmanın girişini normalize eden yığın normalizasyonu kullanır.

- **Grup Normalizasyon** : Yığın normalizasyonda, yığın boyutu 1 seçildiğinde varyans 0 olacağı için normalizasyon işlemi gerçekleşmez. Ayrıca yığın boyutu çok küçük seçildiğinde gürültü oluşur ve bu da eğitimin başarısını etkiler. Dağıtık sistemlerde eğitim yapılmak istendiğinde tüm makinelerdeki yığın normalizasyon boyutu aynı olmalıdır. Aksi takdirde, daha fazla güç ile daha hızlı yapılan eğitim işleminden istenilen verim alınamayacaktır.

Bu sorunları gidermek için Grup Normalizasyonu (GN) tekniği ortaya konulmuştur [67]. GN'de kanallar, gruplara ayrılır ve her grup için ortalama ve varyans hesaplanarak normalizasyon işlemi gerçekleştirilir. GN, yığın boyutlarından bağımsızdır ve çok çeşitli yığın boyutlarında sabit doğruluk vermektedir.



Şekil 3.12. Kaydırma işlemi gösterimi



Şekil 3.13. Yığın ve grup normalizasyonun görsel karşılaştırması


- **Mini Yığın:** Derin öğrenme modellerinin eğitiminde tüm veri setinin tek seferde eğitime sokulması donanımsal kapasite (özellikle RAM kapasitesi) bakımından neredeyse imkânsızdır. Bunun sebebi, her eğitim iterasyonu sonucunda elde edilen sonucun düzeltilmesi aşamasında çok fazla veri üzerinde işlem yapılmasıdır. Kullandığımız veri setine göre bazı durumlarda yüzlerce GB bellek ihtiyacı ortaya çıkacaktır. Bu noktada da eğitim işlemi başarısız olacaktır. Ağın eğitim performansını artırmak, bellek ve zaman açısından maliyeti düşürmek için tüm veriyi tek bir seferde almak yerine veriyi belirli gruplar halinde almak ve küçük gruplar halinde işlem yapmaya mini-yığın denilmektedir. Söz konusu küçük gruplara rastgele şekilde veriler seçilir. Literatürde yapılan çalışmalarda mini yığın boyutu genellikle tüm veri setinin %1 ile %5 arasında bir oranda seçilmektedir.
- **Öğrenme Hızı :** Derin öğrenme sinir ağları Stokastik Eğim İniş (SEİ)(Stochastic Gradient Descent)(SGD) optimizasyonu algoritması kullanılarak eğitilir. Öğrenme hızı, model ağırlıkları her güncellendiğinde tahmini hataya yanıt olarak modeli ne kadar değiştireceğini kontrol eden bir hiper parametredir. Öğrenme oranının çok küçük bir değer seçilmesi modelin eğitimi açısından uzun ve zorlayıcı bir süreç oluştururken, çok büyük bir değer seçilmesi ise düşük bir ağırlık grubunun çok hızlı öğrenilmesine veya kararsız bir eğitim sürecine neden olabilmektedir. Bu nedenle öğrenme hızı, derin sinir ağını konfigüre ederken en önemli parametrelerden biri konumundadır. Öğrenme hızı, parametrik değeri sabit bir katsayı olarak seçilebileceği gibi belirli düzeyde artış veya azalış gösteren şekilde ayarlanabilir bir değer (0,1 ile 0,000001 arasında) seçilebilir.

- **Eğitim Adımı :** Bir model eğitimi esnasında veri setindeki tüm veriler aynı anda eğitim işlemine katılmaz. Veri setindeki veriler mini-yığınlar halinde eğitime sokulurlar. İlk mini-paket eğitilir ve ardından modelin başarısı test edilir. Test sonucuna göre geri yayılım (back-propagation) ile model ağırlıkları güncellenir. Daha sonra yeni bir mini-paket kümesi ile model tekrar eğitilip ağırlıklar tekrar güncellenir. Bu işlem her bir eğitim adımında tekrarlanarak model için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine eğitim dönemi denir.

3.5. Ağırlık Standardizasyonu

Literatürde yer alan derin öğrenme çalışmalarına bakıldığında, mini-paket tekniği kullanıldığı ve bu tekniğin görüntü boyutunun en alt seviye olarak genellikle GİB başına 32 görüntü olarak başladığı görülmektedir. Bu sayı 2'nin katları (64,128,256,...) olarak arttırılabilir ancak daha önce bahsedilen paket normalizasyon tekniğinin yapısı gereği 32 sayısının azaltılması eğitimin istenilen başarıyı elde etmesini engellemektedir. Mini-paket sayısının artması doğal olarak ekran kartı bellek ihtiyacını arttırır. Bu sorunun üstesinden gelmek için, paralel olarak çalışan birden fazla GİB barındıran oldukça pahalı sunucu sistemler üretilmiştir. Araştırmacıların bu sistemlere ulaşım imkânı halen kısıtlıdır.

Bu sorunun çözümü olarak Ağırlık Standartlaştırma(AS) tekniği öne sürülmüştür [68]. Ağırlık standardizasyonu, her GİB'nun eğitim esnasında yalnızca 1 veya 2 görüntü ile işlem yaptığı mikro-paket eğitimini sağlayan bir yapıdır. AS tekniği temel anlamda çok basittir. Paket ve Grup Normalizasyonu gibi geleneksel teknikler temel olarak özellik etkinleştirme işleminde normalizasyon gerçekleştirirken; AS, ağırlıkta (evrişim filtresinde) normalizasyon işlemi gerçekleştirir (Şekil 3.14).



Şekil 3.14. Normalizasyon metodlarının karşılaştırması

Ağırlık Standardizasyonunda, orijinal ağırlıklar üzerindeki L kaybını doğrudan optimize etmek yerine; ağırlıklar, \hat{W} 'nin bir fonksiyonu olarak yeniden değerlendirilir. Özetle ağırlık standardizasyonunda, $\hat{W} = WS$ (W) ve W üzerindeki L kaybı SEİ ile optimize edilir:

$$\hat{W} = \left[\hat{W}_{i,j} \mid \hat{W}_{i,j} = \frac{\hat{W}_{i,j} - \mu w_i}{\sigma w_i + \varepsilon} \right] \quad (3.2)$$


$$y = \hat{W} * x \quad (3.3)$$

$$\mu w_i = \frac{1}{I} \sum_{j=1}^I W_{i,j}, \sigma w_i = \sqrt{\frac{1}{I} \sum_{i=1}^I (\hat{W}_{i,j} - \mu w_i)^2} \quad (3.4)$$

Eşitlik 3.2'de ε , bölme işleminin sonsuz olmasını engellemek için kullanılır, ancak çok küçük bir değerdir (neredeyse 0). Ayrıca, eşitlik 3.4'de, μw_i , her bir çıkış kanalının çekirdek bölgesi içindeki giriş kanallarının ağırlık toplamını belirtir ve σw_i , ağırlıkları yeniden ölçmek ve μw_i arasındaki farkın karekökünü belirtir. Eşitlik 3.3'de ağırlık(bias) terimi 0 olarak ayarlanmış standart bir evrişimli katmanın çıkış özellik haritası hesaplanmaktadır. Eşitlik 3.3'deki \hat{W} ifadesini yeniden parametrik hale getirilerek Eşitlik 3.4'deki WS ifadesi elde edilmektedir.

3.6. Deforme Edilebilir Evrişim

Standart Evrişimli Sınır Ağı, giriş özellik haritasını sabit lokasyonlarda örnekler ve örneklerin ağırlıklı toplamlarını hesaplayarak çıkış üretir. Bu durum özellikle uzaktan algılama görüntülerinde yer alan küçük nesnelere özellik haritalarını çıkarmada istenilen sonucu verememektedir. Son zamanlarda, bu tarz standart evrişimsel sınırlamalarının üstesinden gelmek için deforme edilebilir evrişim [69] önerilmiştir (Şekil 3.15).



Şekil 3.15 Deforme edilebilir evrişim yapısı [56]

Deforme olabilir evrişim, daha büyük nesnelere için evrişim alıcısı alanı genişletmektedir. Her bir ofset arasındaki ortalama mesafeler (Şekil 3.16'deki mavi kareler) etkili genişlemeyi ayarlar. Böylece, daha büyük nesnelere üzerinde merkezlenen deforme olabilen filtreler daha büyük alıcısı alanına sahip olurlar.



Şekil 3.16. Deforme edilebilir evrişim işlemi örnekleri

Standart evrişim, normal bir ızgara yapısı üzerinde çalıştırılır. Deforme edilebilir evrişim de normal ızgara üzerinde çalıştırılır, ancak her bir nokta öğrenilebilir bir ofset ΔP_n ile çarpılarak arttırılır. Deforme edilebilir evrişim işleminde, her 2 boyutlu ofset ΔP_n (her ofset için x yönü ve y yönü) değerine karşılık gelen $2N$ özellik haritası üretilir.


Standart evrişim, Eşitlik 3.5 ile hesaplanır;

$$y(p_0) = \sum_{P_n \in \mathcal{R}} w(P_n) \cdot x(P_0 + P_n) \quad (3.5)$$

Deforme Edilebilir Evrişim ise Eşitlik 3.6 ile hesaplanır;

$$y(p_0) = \sum_{P_n \in \mathcal{R}} w(P_n) \cdot x(P_0 + P_n + \Delta P_n) \quad (3.6)$$

P_n , R konumlarını sıralamak için kullanılırken, w ve P_0 sırasıyla çıkış yeri için ağırlığı ve önceden belirlenmiş ofseti göstermek için kullanılır. Eşitlik 3.5 'de, çıkış özelliği eşleşmesi, y cinsinden her p_0 konumu için hesaplanır. Eşitlik 3.6 'ya ek olarak, Eşitlik 3.3 'de ΔP_n ofseti dikkate alınır.



Şekil 3.17. Standard evrişim (solda), deforme edilebilir evrişim (sağda)

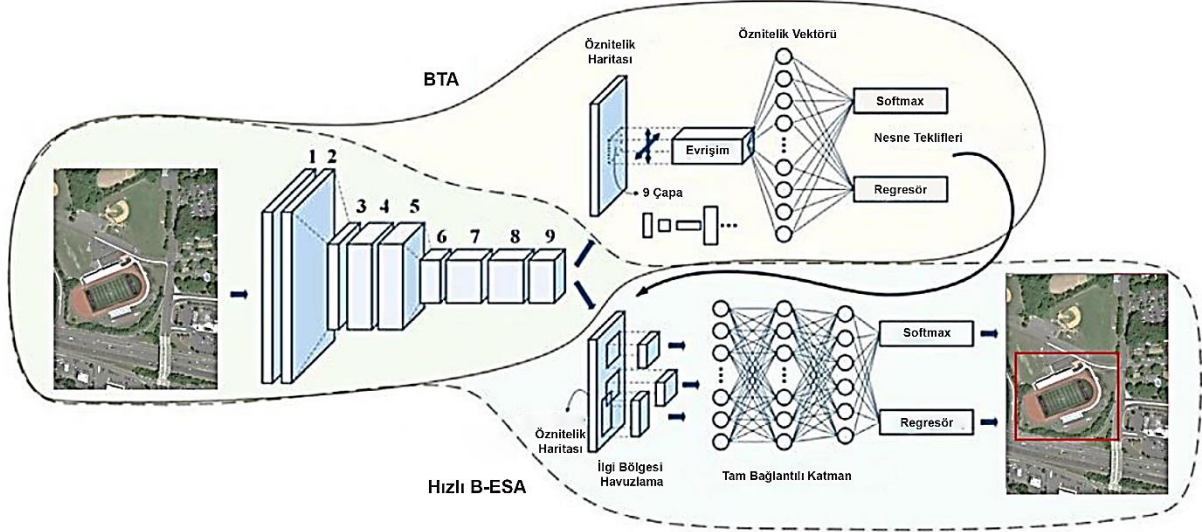
Şekil 3.17’de görüldüğü üzere; deforme edilebilir evrişim, giriş görüntüsünde veya özellik haritalarında standart evrişim için değerleri farklı konumlardan seçer. Bunun sonucunda; daha büyük nesnelere sabitlenmiş deforme edilebilir evrişim, daha fazla alıcı(receptive) alanı seçer ve nesnelere ile ilgili daha fazla öznelik(feature) ortaya çıkarır. Bu da görüntülerdeki küçük nesnelere tespitini kolaylaştırmaktadır.

3.7. Daha Hızlı Bölgesel Evrişimli Sinir Ağı

Literatür özetinin yer aldığı ikinci bölümde bahsedilen Daha Hızlı B-ESA, derin öğrenme nesne tespit uygulamalarında oldukça sık kullanılan, neredeyse bir endüstri standardı haline gelen bir nesne tespit algoritmasıdır. Daha Hızlı B-ESA algoritması 2 aşandan oluşmaktadır. Bunlar; Bölgesel Teklif Ağı (BTA) ve Nesnelere Tespit Ağı’dır (Şekil 3.18).

Bölge teklif ağı, çapa (anchor) olarak adlandırılan bölgesel alanları içerisinde obje bulunabilme oranına (genellikle bu oran %70’dir) göre derecelendirir ve belirli bir oranı geçen bölgeleri nesne tespit ağına gönderir. Çapalar, Daha Hızlı B-ESA algoritmasında önemli bir rol oynar. Çapa aslında boyutları belirli bir kutudur. Daha Hızlı B-ESA’da standart olarak farklı ölçek ve boyutlarda 9 çapa vardır. Bölgesel teklif ağı aşamasında bu çapalar resim üzerinde dolaştırılarak nesne içerebilecek alanlar tespit edilir [26]. Bölgesel teklif ağının çıkışları çapaların farklı boyutları nedeniyle sabit değildir. Nesne tespit ağının girişi ise

sabittir. İki ağ arasındaki uyumsuzluğu gidermek için İlgi Bölgesi Havuzlama (İBH) tekniği kullanılır. İBH'nin yardımıyla boyutları farklı olan bölgelerin boyutları eşitlenir.



Şekil 3.18. Daha Hızlı B-ESA yapısı [26]

Nesne tespit ağında 2 işlem yapılır. İlk olarak bölge içerisindeki arka plan ve ön plan nesnelerinin sınıflandırılmasıdır. Sınıflandırma sonucu ortaya çıkan ön plan nesnesi, farklı çapa boyutlarından dolayı birden fazla kutucuk ile temsil edilir. Bu noktada maksimum bastırma metodu ile en yüksek orana sahip kutucuk seçilir ve nesne böylece tespit edilmiş olur.


3.8. Özellik Piramit Ağı

BTA çok başarılı sonuçlar vermesine rağmen bazı sıkıntıları bulunmaktadır. Bunlar:

- Görüntü alt örnekleme yapılması ile oluşturulan özellik haritası, alt seviyelerdeki birçok anlamsal bilgiyi kaybeder. Bu nedenle de görüntüdeki küçük nesnelere tespit edemez,
- BTA'da kullanılan kayıp fonksiyonunda iyi sınıflandırılmış örneklerin kaybına odaklanılır. Bu da örnekler arasında ciddi fark olan dengesiz veri setlerinde başarısız sonuçlara neden olur.

Bu problemleri çözmek için Özellik Piramit Ağı (ÖPA) [71] tekniği ortaya konulmuştur. Bu yöntemde; evrişimsel özellik hiyerarşisinin piramidal şeklinden yararlanırken tüm


ölçeklerde anlamsallığı güçlü olan bir özellik piramidi oluşturulmaktadır. Yöntem bunu yaparken, Şekil 3.19'da gösterildiği gibi, yukarıdan aşağıya geçiş yolu ve yanal bağlantı yoluyla; düşük çözünürlüklü ve semantik açıdan güçlü öznitelikler ile yüksek çözünürlüklü ve semantik açıdan zayıf olan öznitelikleri birleştiren bir mimari ortaya koyulmuştur.



Şekil 3.19 Özellik piramit ağı yapısı [71]

3.9. Odaksal Kayıp

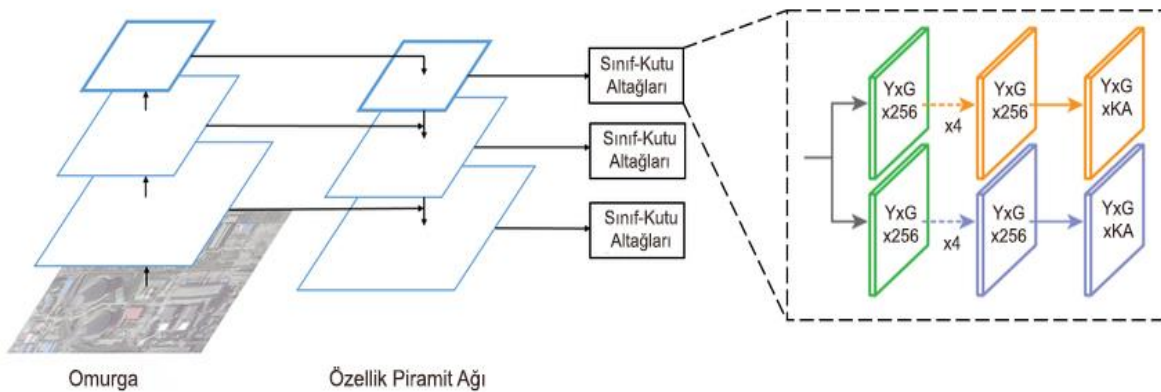
Odaksal Kayıp tekniğinde, standart Çapraz Entropi(Cross Entropy) kriterlerine bir faktör $(1 - pt)$ ekleyen yeni bir kayıp önerilmektedir[72]. Böylece, iyi sınıflandırılmış örneklerin göreceli kaybını azaltılır, sert, yanlış sınıflandırılmış örneklere daha fazla odaklanılır. Önerilen odak kaybı, çok sayıda kolay arka plan örneğinin mevcudiyetinde yüksek hassasiyetli yoğun nesne detektörlerinin eğitilmesini sağlar. Odaksal Kayıp'ın grafik gösterimi Şekil 3.20'de verilmiştir.



Şekil 3.20 Odaksal Kayıp [72]

3.10 Retina Ağı


Retina Ağı, bir omurga ağından ve iki göreve özel alt ağlardan oluşan tek ve birleşik bir ağıdır[72]. Nesne tespit başarısını arttırmak için Özellik Piramit Ağı ve Odaksal Kayıp kullanılmaktadır. Retina Ağı modelinde; omurga, bir giriş görüntüsünün tamamı üzerinde bir evrişimsel özellik haritasının hesaplanmasından sorumludur ve kendi kendine bir evrişim ağıdır. İlk alt ağ, omurga çıktısı üzerinde sınıflandırma yapar; ikinci alt ağ, evrişim sınırlayıcı kutu regresyonunu gerçekleştirir. Retina Ağı, son zamanlarda nesne tespiti konusunda oldukça başarılı sonuçlar elde etmektedir.



Şekil 3.21 RetinaAğı yapısı [72]

3.11. Tek Atışlık Detektör(TAD)

Tek Atışlık Detektör algoritması, sınırlayıcı kutuların çıkış alanını, özellik harita konumu başına farklı en boy oranları ve ölççekler üzerinden bir dizi varsayılan kutuya ayırır. Tahmin esnasında, algoritma varsayılan kutu içerisinde yer alan her nesne kategorisinin varlığı için puanlar üretir ve nesne şeklini daha iyi eşleştirmek için kutuların boyutunu ayarlar[38]. Ayrıca, farklı boyutlardaki nesnelerin doğal olarak ele alınabilmesi için, farklı çözünürlüğe sahip çoklu öznetelik haritalardan gelen tahminler birleştirilir (Şekil 3.22).



Şekil 3.22 Tek atışlık detektör yapısı [38]

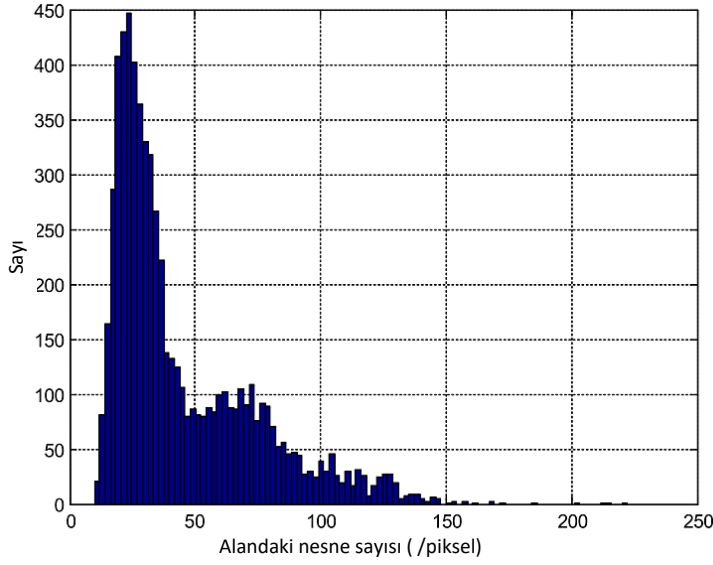
4. UZAKTAN ALGILAMA GÖRÜNTÜLERİNDEKİ NESNELERİN TESPİTİ

Bu tez çalışmasında uzaktan algılama görüntülerindeki nesnelere tespiti için iki farklı model önerisi yapılmıştır. İlk model Daha Hızlı B-ESA modelinin geliştirilmiş bir halidir. İkinci model ise 3 farklı nesne tespit modelinin (Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA) katsayılı ağırlıklı topluluk olarak nesne tespiti yaptığı işbirlikçi bir nesne tespit modelidir. Bu bölümde önerilen modeller detaylı olarak açıklanmaktadır.

4.1. Model 1 : Geliştirilmiş Daha Hızlı B-ESA

Birinci model olan Geliştirilmiş Daha Hızlı B-ESA, nesne tespiti konusunda oldukça başarılı olan Daha Hızlı B-ESA algoritması baz alınarak tasarlanmıştır. Daha Hızlı B-ESA algoritması, görüntülerin öznitelik haritalarını çıkarmak için ESA kullanmaktadır. Ancak uzaktan algılama görüntülerinde yer alan küçük ve arka planları karışık nesnelere tespitinde ESA yapısı zayıf kalmaktadır.

Daha Hızlı B-ESA algoritmasının görüntülerden öznitelik çıkarım sürecinde, bölge teklif ağı (BTA) ile nesne tespit detektörleri evrişimli katmanları paylaşır. Pascal VOC [73], MS Coco [74] ve ImageNet [75] gibi kıyaslama veri setleri, uzaktan algılama görüntülerine oranla daha büyük nesnelere içermektedir. BTA, söz konusu veri setleri için geniş bir ölçek ve en-boy oranı sunarak etkili bir şekilde bölge teklifleri yapabilmek için tasarlanmıştır. Ancak en küçük BTA çapa kutusu bile uzaktan algılama görüntülerindeki birçok nesne için hala büyüktür. Tez çalışmasında kullandığımız NWPU-VHR10 veri setinde yer alan nesnelere boyut histogramı Şekil 4.1’de verilmiştir.

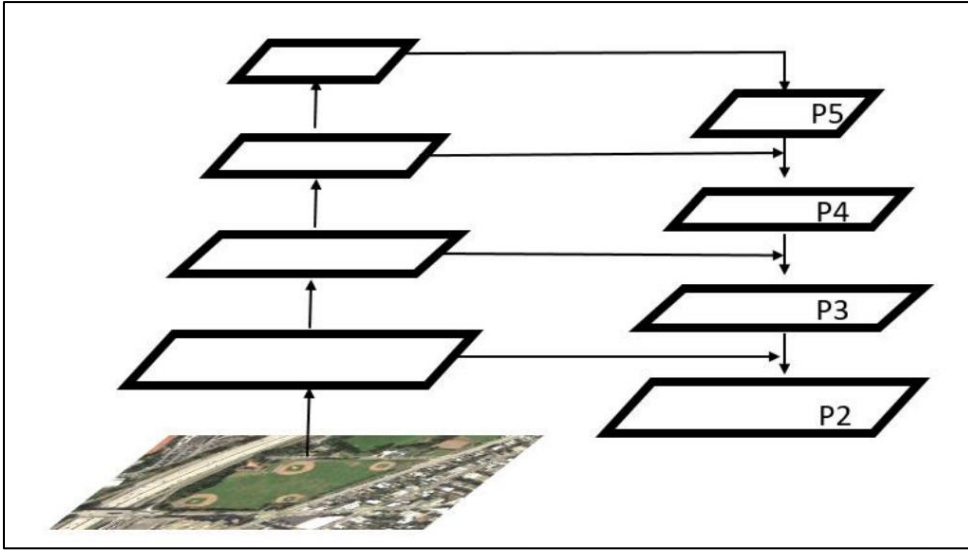


Şekil 4.1. VHR10 veri setinde yer alan nesnelerin boyut histogramı [76]

Şekil 4.1’de görüleceği üzere NWPU-VHR10 veri setindeki nesnelerin boyutu çoğunlukla 10 ile 100 piksel arasında değişmektedir. Tez çalışmasında temel aldığımız Daha Hızlı B-ESA algoritmasında ise çapa boyları 128, 256 ve 512 piksel, en-boy oranı da 0.5, 1 ve 2 olarak seçilmiştir. Bu da uzaktan algılama görüntüleri gibi çok küçük nesne boyutlarına sahip veri setlerinde tespit başarısını düşürmektedir. Önerilen Geliştirilmiş Daha Hızlı B-ESA modelinde bu sorunu çözmek için;

- 0.5, 1, 2 en-boy oranlarına ek olarak 0.25 ve 0.125 en-boy oranları,
- 128, 256, 512 piksel çapa boyutlarına ek olarak 16,32,64 ve 128 piksel çapa boyutları da BTA’na dâhil edilmiştir.

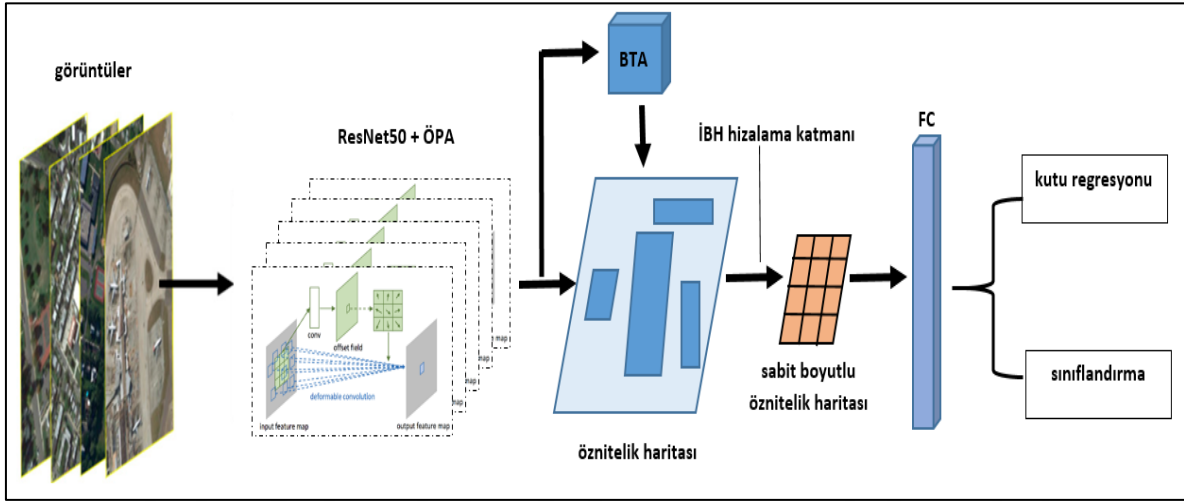
Uzaktan algılama görüntülerinde alt örnekleme yapılarak oluşturulan öznitelik haritası, alt seviyelerdeki birçok anlamsal bilgiyi kaybeder. Bu nedenle de görüntüdeki küçük nesneleri tespit etmedeki başarısı düşmektedir. Bu sorunu çözmek için Geliştirilmiş Daha Hızlı B-ESA modelinde ÖPA yapısı kullanılmıştır. ÖPA sayesinde uzaktan algılama görüntülerindeki sığ katmanlarındaki yüksek çözünürlüklü özellikler nesne tespit ağına aktarılır.



Şekil 4.2 Nesne tespit modeli ÖPA yapısı

Görüntülerden öznitelik haritası çıkarmak için kullanılan evrişimli ağların derinliği arttıkça bazı problemler ortaya çıkmaktadır. Bunlar; ağın eğitimi sırasında geri yayılım işleminde bazı nöronların kaybolması (vanishing gradient) ve derinlik arttıkça farklı yapılardan kaynaklı parametrelerin artış göstermesidir. Literatürde bu sorunu çözmek için ResNet [77] yapısı ortaya konulmuştur. Geliştirilmiş Daha Hızlı B-ESA modelinin söz konusu sorunları gidermesi için; öznitelik çıkarımı yapılan evrişimli sinir ağı, ResNet50 modeli ile gerçekleştirilmiştir. Ayrıca, oldukça küçük nesnelere içeren uzaktan algılama görüntülerindeki öznitelik çıkarma işleminin başarısını arttırmak için, standart evrişim yerine deforme edilebilir evrişim yapısı tercih edilmiştir. Tez çalışmasının üçüncü bölümünde bahsedildiği üzere düşük güçlü GİB'leri ile uzaktan algılama görüntülerinde nesne tespiti yapabilmek için ağırlık standartlaştırma tekniği kullanılmaktadır. Geliştirilmiş Daha Hızlı B-ESA modelinde de bu teknikten faydalanılarak elimizde mevcut olan ve derin öğrenme eğitimi için nispeten düşük GİB (Nvidia GTX 1080) ile eğitim yapılabilmektedir.

Yukarıda bahsedilen ön bilgiler ışığında; Geliştirilmiş Daha Hızlı B-ESA'da, yüksek çözünürlüklü uzaktan algılama görüntülerinden öznitelik çıkarmak için deforme edilebilir evrişim yapılı ResNet50 ağı kullanılmaktadır. Ayrıca, daha yoğun bir öznitelik haritası elde edebilmek için, öznitelik çıkarma ağının giriş çözünürlüğünün çıkış çözünürlüğüne oranı olan çıkış adım sayısı, 32 olarak seçilmiştir. Öznitelik çıkarma ağı, ÖPA üzerinden çok ölçekli olarak beslenmektedir. Geliştirilmiş Daha Hızlı B-ESA modelinin yapısı Şekil 4.3'te görülmektedir.

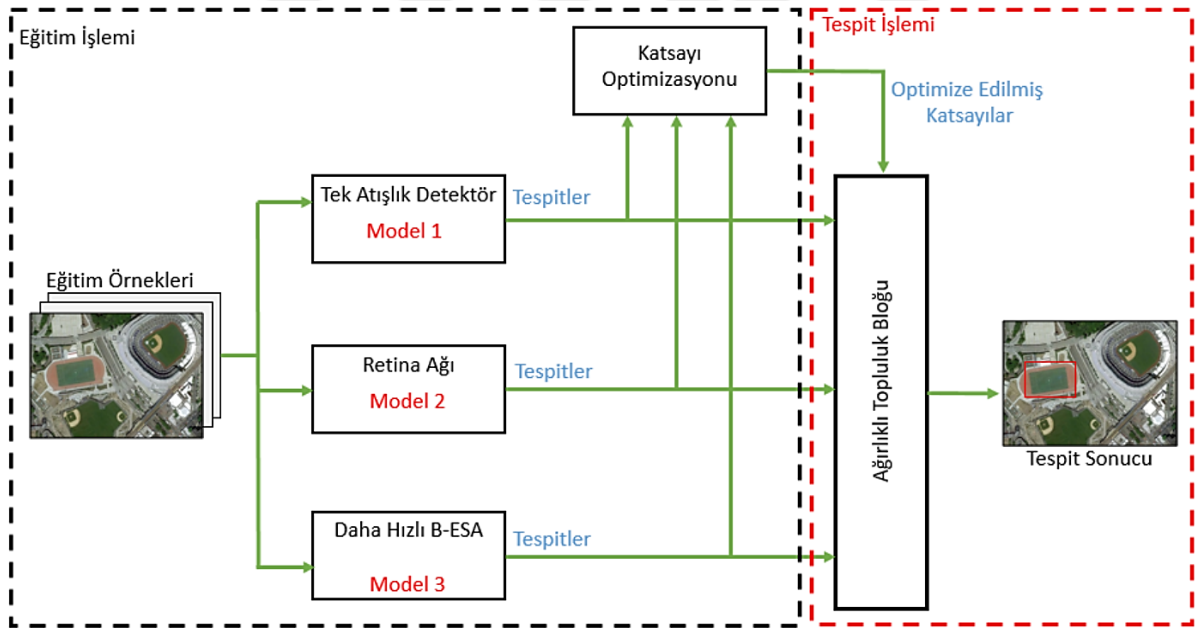


Şekil 4.3. Geliştirilmiş Daha Hızlı B-ESA yapısı

Şekil 4.3'te görülen nesne tespit modelinde, öznitelikler deforme olabilir bir evrişim ağı olan ResNet50 omurgası tarafından elde edilir. Standart ResNet50 ağı, evrişimli sinir ağından oluşurken, Geliştirilmiş Daha Hızlı B-ESA'daki ResNet50 ağı deforme olabilir bir evrişim yapısını kullanır. Böylece, uzaktan algılama görüntülerinde daha fazla alandan öznitelik çıkarımı yapılabilmektedir. Geliştirilmiş Daha Hızlı B-ESA modelinde kullanılan ÖPA yapısı sayesinde; Şekil 4.2'de görülen P2, P3, P4, P5 katmanlarından elde edilen özellikler Geliştirilmiş Daha Hızlı B-ESA modeline verilebilmektedir. Ayrıca Geliştirilmiş Daha Hızlı B-ESA modelinin, tez çalışması kapsamında kullandığımız düşük güçlü GİB'de daha etkili eğitiminin yapılabilmesi için Ağırlık Standardizasyonu tekniğinden faydalanılmıştır. Bu teknik sayesinde; eğitim esnasında GİB'e tek bir resim gönderilerek hafıza tüketim sorunu ortadan kaldırılmıştır. Literatürde oldukça sık kullanılan paket normalizasyonu kullanan nesne tespit modellerinin eğitilmesi esnasında GİB başına 32 resim hatta bazen 64 resim gönderildiği düşünüldüğünde, ağırlık standardizasyonun etkisi daha iyi anlaşılacaktır.

4.2. Model 2: Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modeli

Son yıllarda uzaktan algılama görüntülerindeki nesne tespitinde, topluluk modellerinin kullanıldığı çalışmaların da öne çıktığı görülmektedir. Bu çalışmalarda; birden fazla çok katmanlı algılayıcı, koşullu rastgele alanlar ve ya ESA ağı topluluk hale getirilerek yapısal olarak bütün olan tek bir model ortaya konulmaktadır. Ardından model eğitilir ve nesne tespiti sağlanır. Ortaya konulan bu modeller, belirli bir yapısal koşullara bağlı olduğu için model üzerinde değişiklik yapılması zor hale gelmektedir. Ayrıca bu çalışmaların tamamında, eğitim esnasında topluluk işlem yapılmaktadır. Esnek ve eğitimden bağımsız bir topluluk işleminin daha pratik ve etkili olacağı fikri kapsamında çalışmamızda; tez çalışması kapsamında önerilen ikinci model, aynı veri seti üzerinde birbirinden bağımsız olarak eğitilmiş 3 tane farklı nesne tespit modeli kullanılarak optimize edilmiş katsayı ağırlıklı topluluk nesne tespiti yapan bir yapıdır. Şekil 4.4'de Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modelinin yapısı görülmektedir.



Şekil 4.4 Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modelinin yapısı

Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modelinde, aynı veri seti üzerinde eğitilmiş 3 farklı nesne tespit modeli kullanılmaktadır. Bu modeller; Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA'dır. TAD ve Retina Ağı tek aşamalı nesne tespit modeli iken Daha Hızlı B-ESA 2 aşamalı bir nesne tespit modelidir. Bu nesne tespit modelleri birbirinden bağımsız olarak eğitilmiştir.

Önerilen nesne tespit modeli, 3 tane farklı nesne tespiti sonuçlarını giriş olarak alır ve tek bir nesne tespiti sonucu üretir. Buradaki nesne tespit kavramı, bir görüntüdeki birden çok nesnenin konumunu ve kategorisini belirleme görevidir. Bir nesne algılama modeli, bir görüntü verildiğinde $T = [t_1, \dots, t_N]$ algılamalarının bir listesini döndüren bir işlev olarak görülebilir. Bu formülde, her t_i 'ye karşılık gelen bir sınırlayıcı kutu (b_i), sınıf (c_i) ve güven skorundan(s_i) oluşan üçlü $[b_i, c_i, s_i]$ üretilir.

Modelin girişi, 3 farklı nesne tespit modelinin verilen bir görüntüdeki nesne tespitlerinin bir listesidir ($TL = [T_1, T_2, T_3]$). Her bir TL , 3 farklı b_i , c_i , ve s_i değerlerine sahiptir. Bu kapsamda, Katsayı Ağırlıklı Topluluk Nesne Tespit Modelinin çalışma adımları aşağıda verilmiştir:

1. TL 'de yer alan nesne tespitleri, sınıf değerlerine ve sınırlayıcı kutuların çakışma gelme durumlarına göre gruplandırılır. Sınırlayıcı kutuların çakışmasını belirlemek için IoU metriği kullanılır. İki sınırlayıcı kutu b_1 ve b_2 olarak göz önüne alındığında, aralarındaki örtüşen bölgeyi bulmak için aşağıdaki IoU eşitliği kullanılır.

$$IoU(b_1, b_2) = \frac{\text{alan}(b_1 \cap b_2)}{\text{alan}(b_1 \cup b_2)} \quad (4.1)$$

2. $IoU > 0.5$ olan sınırlayıcı kutular yeni bir listeye (Çakışma Listesi - $ÇL$) atılır. $ÇL$ 'de her bir nesne tespiti için b_i ve c_i değerleri yer almaktadır. $ÇL$ 'deki kümelenmiş halde çoklu farklı kutucuklar için ağırlık katsayıları (k_i) kullanılarak yeniden ortak bir kutucuk ve güven skoru hesaplanması gerekmektedir. Bu hesaplamalar aşağıdaki eşitliklerle yapılır:

$$S = \frac{k_1 * S_1 + k_2 * S_2 + k_3 * S_3}{k_1 + k_2 + k_3} \quad (4.2)$$

$$X1 = \frac{k_1 * X1_1 + k_2 * X1_2 + k_3 * X1_3}{k_1 + k_2 + k_3} \quad (4.3)$$

$$X2 = \frac{k_1 * X2_1 + k_2 * X2_2 + k_3 * X2_3}{k_1 + k_2 + k_3} \quad (4.4)$$

$$Y1 = \frac{k_1 * Y1_1 + k_2 * Y1_2 + k_3 * Y1_3}{k_1 + k_2 + k_3} \quad (4.5)$$

$$Y2 = \frac{k_1 * Y2_1 + k_2 * Y2_2 + k_3 * Y2_3}{k_1 + k_2 + k_3} \quad (4.6)$$

Eşitlik 4.2’de güven skoru hesaplanırken tüm güven skorlarının ağırlık katsayıları ile çarpımlarının ortalaması alınır. Aynı şekilde sınırlayıcı kutunun koordinatları da her biri kendi içerisinde ayrı ayrı ağırlık katsayılarının çarpımı neticesinde hesaplanır (Eşitlik 4.3 – 4.6).

3. *TL*’de yer alan nesne tespitlerinden en az 2’sinin üst üste gelmesi durumunda Eşitlik 4.2 – 4.6 işlemleri yapılmaktadır. Ortaya çıkan topluluk nesne tespitleri, Nesne Tespit Listesine (*NTL*)’e atılır. Bu noktada hiç çakışmayan nesne tespitleri olabilmektedir. Bu tarz nesne tespitlerinden güven skoru (c) > 0.5 olanlar da *NTL*’ye atılmaktadır.
4. *NTL*’de yer alan nesne tespitleri, sonuç tespitleri olarak kabul edilir ve katsayı ağırlıklı topluluk nesne tespit işlemi sona erer.

Katsayıların Optimize Edilmesi: Kullandığımız 3 modelden elde edilen nesne tespit sonuçlarına göre optimal katsayıların hesaplanması işlemidir. Bu süreçte, test veri kümesindeki etiketlerin $X1, Y1, X2, Y2$ koordinat değerlerine en yakın olan üç modelin $X1, Y1, X2, Y2$ koordinat değerlerini birbirine dönüştüren katsayılar doğrusal olmayan programlama ile hesaplanır [78]. Bu işlemde, tüm test verileri bir bütün olarak düşünülerek optimizasyon yapılır. Optimizasyon işlemi aşağıdaki eşitliklerle yapılır:

$$\hat{Y}_i = \sum_{n=1}^3 \frac{k_n * X_{in}}{k_{sum}}, X_{in} = (X1_n, Y1_n, X2_n, Y2_n) \quad (4.7)$$

$$k_{sum} = k_1 + k_2 + k_3 \quad (4.8)$$

$$Kısıtlar : \sum_{n=1}^3 k_n = 1 , \quad k_n \geq 0 \quad (4.9)$$

$$Z_{min} = \sum_{i=1}^K (Y_i - \hat{Y}_i)^2 \quad (4.10)$$

Denklem 4.8'de, \hat{Y}_i tahminlerin toplamını temsil eder, k_n katsayıları ve X_{in} sembolü de n 'inci modelin i 'inci tahmininin koordinat değerlerini (X_1, Y_1, X_2, Y_2) belirtir. Denklem 4.9, katsayılar toplamının formülüdür. Denklem 4.10, gerçek koordinat değerleri ile tahmini koordinat değerleri arasındaki farkın karelerinin toplamını en aza indiren optimizasyon hedef işlevidir. Optimizasyon objektif fonksiyonunun kısıtları denklem 4.9'da verilmiştir. Optimizasyon objektif fonksiyonunun minimum değeri bulunurken, Ortalama Kare Sapma (MSD) [79] tekniği kullanılır. Z_{min} değerini sağlayan k_1, k_2, k_3 değerleri en uygun katsayılarıdır.

5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, tez çalışması kapsamında ortaya koyduğumuz nesne tespit modellerinin başarısının ölçülmesi maksadıyla yapılan deneyler, bu deneylerin yapıldığı ortam ve kullanılan veri seti, deney sonuçlarını değerlendirme kriterleri ve son olarak önerilen modellerin NWPU-VRH10 veri setini kullanan diğer çalışmalar ile kıyaslanması yer almaktadır.

5.1. Çalışma Ortamı ve Değerlendirme Kriterleri

Deneyler, Intel® Core™ i5 2.4 Ghz CPU, 6 GB RAM, tek Geforce GTX1080 ekran kartı ve Ubuntu 16.04 LTS işletim sistemi olan bir masaüstü bilgisayarı üzerinde mmdetection toolkit[80] kullanılarak yapılmıştır. Program kodları, pytorch kütüphanesi[81] kullanılarak python[82] dilinde yazılmıştır. Önerilen modelin performansını değerlendirmek için Hassasiyet–Geri Çağırma Eğrisi (HGE)(Precision-Recall Curve)(PRC) ve Ortalama Hassasiyet (OH)(Average Precission)(AP) değerlendirme kriterleri kullanılmıştır. Bu 2 kriter, literatürde standartlaşmış ve birçok nesne tespit çalışmasında [83 - 88] kullanılmıştır.

Hassasiyet–Geri Çağırma Eğrisi: Hassasiyet, gerçek pozitif tespitlerinin kesinliğini, Geri Çağırma değeri ise doğru olarak tanımlanan doğru pozitiflerin oranını belirler. DP, YP ve YN sırasıyla doğru pozitiflerin sayısı, yanlış pozitiflerin sayısı ve yanlış negatifleri belirtmek için kullanılır. Bu kapsamda HGE değeri aşağıdaki eşitlikler ile hesaplanır;

$$Hassasiyet = \frac{GP}{(GP + YP)} \quad (5.1)$$

$$Geri \text{ Çağırma} = \frac{GP}{(GP + YN)} \quad (5.2)$$

Öngörülen sınırlama kutusu ile yer gerçeği sınırlama kutusu arasındaki alan örtüşme oranı 0,5'i geçerse, tespitin gerçek pozitif olduğu kabul edilir. Aksi halde tespit yanlış pozitif olarak kabul edilir. Ayrıca, birden fazla tespit aynı temel doğruluk sınırlama kutusuyla çakışırsa, yalnızca bir tanesi gerçek pozitif olarak kabul edilir, diğerleri ise yanlış pozitif olarak kabul edilir.


Ortalama Hassasiyetlerin Ortalaması : Geri Çağırma değerinin 0 ile 1 arasındaki değerlerinin, yani HGE altındaki alandaki aralık boyunca ortalama hassasiyet değerlerinin ortalamasının hesaplanmasıdır. Bu nedenle, OHO değeri ne kadar yüksek olursa, performans o kadar iyi olur.

F1 Skoru : Geri çağırma ve hassasiyet iki önemli metriktir ve aralarında bir ilişkisel bir değiş-tokuş durumu vardır. Söz konusu bu değiş-tokuş bazı durumlarda sorun oluşturmaktadır. Sorunu çözebilmek için F1-skoru kullanılmaktadır. F1-skoru aşırı durumları cezalandırmak için aritmetik ortalama yerine harmonik ortalamayı kullanılmaktadır. F1 skoru hesaplaması Eşitlik 5.3’de verilmiştir.

$$F_1 = 2 * \frac{\text{hassasiyet} * \text{geri çağırma}}{\text{hassasiyet} + \text{geri çağırma}} \quad (5.3)$$

5.2. Kullanılan Veri Seti

Önerilen modellerin deneyleri için NWPU-VHR10[5] veri seti kullanılmıştır. Veri seti, 10 sınıf içermektedir. Bunlar; uçak, gemi, yakıt tankı, beyzbol sahası, tenis sahası, basketbol sahası, koşu pisti, liman, köprü ve araç’dır. Veri setinde yer alan görüntülerden sınıf bazlı örnekler Şekil 5.1’de görülmektedir.



Şekil 5.1. NWPU-VHR10 veri seti örnek görüntüler

Bu veri seti, her görüntünün sınıf nesnelere en az bir tanesini içerdiği 650 görüntü ve hiçbir nesne içermeyen 150 görüntüden oluşmaktadır (toplam 800 görüntü). Nesne içeren 650 görüntü manuel olarak etiketlenmiştir ve pozitif görüntü kümesi olarak kabul görmektedir. Aynı şekilde hiçbir nesne içermeyen 150 görüntü ise negatif görüntü kümesidir. Nesne içeren 650 görüntü kümesi, Google Earth programından [89] elde edilen 0.2 m ile 2 m arasında değişen uzamsal çözünürlüğe sahip 565 görüntü ve Vaihingen veri setinden [90] elde edilen 0.08 m uzamsal çözünürlüğe sahip 85 keskinleştirilmiş görüntüden oluşmaktadır. Bu durum NWPU-VHR10'u literatürde oldukça sık kullanılan zorlu bir veri seti haline getirmektedir. Pozitif görüntü kümesi, 302 gemi, 477 araç, 124 köprü, 224 liman, 655 koşu pisti, 390 bezbol sahası, 524 tenis sahası, 159 basketbol sahası, 163 yakıt tankı ve 757 uçak nesnesi içermektedir (Çizelge 1).

Çizelge 5.1. Pozitif görüntü kümesi sınıf bazında nesne sayıları


Sınıf Adı	Toplam Nesne Sayısı
Uçak	757
Gemi	302
Yakıt Tankı	163
Beyzbol Sahası	390
Tenis Sahası	524
Basketbol Sahası	159
Koşu Pisti	655
Liman	224
Köprü	124
Araç	477

Görüntülerin en boyutları 533 ile 1728 piksel, boy boyutları ise 597 ile 1028 piksel aralığında değişmektedir ve içerdiği nesnelere boyutları da farklılıklar göstermektedir. Görüntülerin içerdiği nesnelere en küçük, en büyük ve ortalama boyutları Çizelge 5.2'de görülmektedir.

Çizelge 5.2. NWPU VHR10 veri seti sınıf bazında nesne boyutları

Sınıf Adı	En Küçük Boyut (piksel)	En Büyük Boyut (piksel)	Ortalama Boyut (piksel)
Uçak	33 x 33	129 x 129	81 x 81
Gemi	40 x 40	128 x 128	84 x 84
Yakıt Tankı	34 x 34	103 x 103	69 x 69
Beyzbol Sahası	49 x 49	179 x 179	114 x 114
Tenis Sahası	45 x 45	127 x 127	86 x 86
Basketbol Sahası	52 x 52	179 x 179	116 x 116
Koşu Pisti	192 x 192	418 x 418	300 x 300
Liman	68 x 68	222 x 222	145 x 145
Köprü	98 x 98	363 x 363	231 x 231
Araç	42 x 42	91 x 91	67 x 67

NWPU-VHR10 veri setindeki eğitim nesnesi sayısı az olduğu için önerilen modelin başarısı düşük çıkacaktır. Bunu önlemek adına veri artırma tekniği kullanılmıştır. Veri artırma adımı; pozitif görüntü kümesindeki resimlere bulanıklaştırma, dikey olarak döndürme, yatay olarak döndürme, gamma dönüşümü ve rastgele renk parlaklığı işlemleri uygulanmıştır. Örnek veri artırma resimleri Şekil 5.2’de görülmektedir.



Şekil 5.2. Veri artırma örnekleri (a) Orijinal resim. (b) Gamma dönüşümü (c) Dikey döndürme (d) Yatay döndürme (e) Rastgele renk parlaklığı (f) Resim bulanıklaştırma.


5.3. Geliştirilmiş Daha Hızlı B-ESA Modelini Kullanarak Farklı Eğitim – Test Veri Seti Oranları ile Yapılan Deneyler

Geliştirilmiş Daha Hızlı B-ESA modelinin, eğitilecek ve test edilecek veri miktarı değişimlerine karşı ne kadar duyarlı olduğunu tespit etmek ve az veri ile eğitilmesi sonucunda ne kadar başarılı olduğunu görmek için farklı eğitim-test veri seti oranları ile deneyler gerçekleştirilmiştir. Her bir deneyde 12 adımlık bir eğitim uygulanmıştır. Seçilen eğitim - test veri seti oranları Çizelge 5.3'te verilmiştir.

Çizelge 5.3. Deney yapılan eğitim – test veri seti oranları

Deney No	Eğitim – Test Veri Seti Oranları
1	%10 - %90
2	%20 - %80
3	%30 - %70
4	%40 - %60
5	%50 - %50
6	%60 - %40
7	%70 - %30
8	%80 - %20
9	%90 - %10


Deney 1: İlk deneyde %10 eğitim verisi olan 65 resim ile modelimiz eğitilmiştir. Ardından %90 test verisi olan 585 resim ile test edilmiştir. Sonuçlar Şekil 5.3'te görülmektedir.



Şekil 5.3. Deney 1 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği


Deney 1’de çok az eğitim verisi kullanıldığı için toplam kayıp yüksek, başarı düşük çıkmıştır.

Deney 2: %20 eğitim verisi olan 130 resim ile modelimiz eğitilmiştir. Ardından %80 test verisi olan 520 resim ile test edilmiştir. Sonuçlar Şekil 5.4’te görülmektedir. Deney 2’de deney 1’e göre 2 kat eğitim verisi kullanıldığı için daha iyi sonuçlar elde edilmiştir. Ancak sonuçlar istenilen seviyenin hala uzağındadır.




Şekil 5.4. Deney 2 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 3: %30 eğitim verisi olan 195 resim ile modelimiz eğitilmiştir. Ardından %70 test verisi olan 455 resim ile test edilmiştir. Sonuçlar Şekil 5.5’te görülmektedir. Sonuçlardan da görüleceği üzere; eğitim verisinin artması daha iyi F1 skoru elde etmemize neden olmuştur.




Şekil 5.5. Deney 3 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 4: %40 eğitim verisi olan 260 resim ile modelimiz eğitilmiştir. Ardından %60 test verisi olan 390 resim ile test edilmiştir. Sonuçlar Şekil 5.6’te görülmektedir.




Şekil 5.6. Deney 4 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 5: Deneyde eğitim ve test veri seti sayısı(325 görüntü) aynıdır. Deney 5'ten itibaren modelimiz daha fazla veri ile eğitime başlanmıştır. Sonuçlar Şekil 5.7'de görülmektedir.




Şekil 5.7. Deney 5 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 6: %60 eğitim verisi olan 390 resim ile modelimiz eğitilmiştir. Ardından %40 test verisi olan 260 resim ile test edilmiştir. Sonuçlar Şekil 5.8'de görülmektedir.




Şekil 5.8. Deney 6 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 7: Literatürde oldukça sık kullanılan eğitim-test oranlarından biri olan %70 eğitim - %30 test verisi oranı ile yapılan deneydir. Sonuçlar 5.9’da görülmektedir.




Şekil 5.9. Deney 7 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 8: Literatürde oldukça sık kullanılan diğer bir eğitim-test oranı olan %80 eğitim - %20 test verisi oranı ile yapılan deneydir. Sonuçlar 5.10’da görülmektedir.



Şekil 5.10. Deney 8 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney 9: Literatürde çok az kullanılan bir eğitim-test veri seti oranı olan %90 eğitim – 10% test veri seti ile yapılan son deneydir. Eğitim verisinin en fazla olduğu deney olmasına rağmen sonuçlar çok yüksek çıkmamıştır. Bunun nedeni olarak aşırı öğrenme (overfitting)'dir. Sonuçlar Şekil 5.11'de görülmektedir.



Şekil 5.11. Deney 9 sonuçları (a) toplam kayıp – doğruluk eğrisi (b) hassasiyet-geri çağırma eğrisi (c) sınıf bazında F1 skoru grafiği

Deney sonuçları incelendiğinde; veri eksikliğinin performansı doğrudan etkilediği görülmektedir. Bu etki F1 skoru grafiklerinde daha belirgin görülmektedir. Tez çalışmasında önerilen modelin nesne tespit performansı, veri seti oranlarında önemli değişikliklere rağmen stabil kalmaktadır. Bu durum, modelimizde yer alan deforme olabilen evrişim yapısının daha fazla alandan öznitelikleri çıkarması ve ÖPA'nın farklı seviyelerden öznitelikleri tespit ağına vermesinden kaynaklanmaktadır. Yapılan deney sonuçlarına göre elde edilen OHO sonuçları Çizelge 5.4.'te görülmektedir.

Çizelge 5.4. Farklı eğitim-test veri oranlarının model performansına etkisi

Eğitim-Test Oranı (%)	10 - 90	20 - 80	30 - 70	40 - 60	50 - 50	60 - 40	70 - 30	80 - 20	90 - 10
OHO	0.587	0.677	0.812	0.841	0.892	0.907	0.923	0.871	0.870


Çizelge 5.4'te yer alan sonuçlar incelendiğinde; eğitim veri setindeki görüntü sayısının azaltılmasıyla, performansın önemli ölçüde azaldığı (başarının neredeyse %40 azaldığı) görülmektedir. Bununla birlikte, modelimizin çok az veriyle (%30 eğitim verisi ile 0.812 OHO oranı) de oldukça başarılı performans göstermiştir. En başarılı sonuç, literatürde sıkça tercih edilen %70 eğitim – %30 test verisi oranında elde edilmiştir. Eğitim verisinin artmasıyla OHO değerinin artması beklenirken, aşırı öğrenme ve test verisinin azlığı nedeniyle yaptığımız bazı deneylerde (Ör. deney 8 ve 9) bu sonuç ortaya çıkmamıştır.

5.4. Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modeli ile Yapılan Deneyler

Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modelinde kullanılan 3 farklı nesne tespit modelinin (sırasıyla Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA) ağırlık katsayıları değiştirilerek modelin tespit performansını değerlendirmek için 8 tane deney yapılmıştır (NWPU-VHR10 veri seti pozitif görüntü kümesi, %70 oranında eğitim ve %30 oranında test verisi olarak kullanılmıştır). Her bir deneyde, topluluk yapısını oluşturan nesne tespit modellerinin ağırlıkları değiştirilerek aşağıda durumlar elde edilmiştir:

- Tüm modellerin katsayıların 1'e eşit olması,
- Bir modelin katsayısının 2'ye, diğer modellerin katsayılarının 1'e eşit olması,
- 2 modelin katsayılarının 2'ye ve üçüncü modelin katsayısının 1'e eşit olması,
- Optimizasyon işlemi sonucuna göre her bir modelin en optimal katsayı değerine sahip olduğu durumlarıdır.


Deney 10: Tüm nesne tespit modellerinin katsayılarının birbirine eşit olması durumunda yapılan deneydir. Deney sonucunda elde edilen hassasiyet-geri çağırma eğrisi ve sınıf bazında F1 skoru grafiği Şekil 5.12'de görülmektedir.



Şekil 5.12. Deney 10 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği


Şekil 5.12’de görüleceği üzere, nesne tespit modellerinin katsayıları birbirine eşit olduğu durumda katsayı ağırlıklı topluluk nesne tespit modeli oldukça gürbüz bir sonuç ortaya koymaktadır.

Deney 11: Retina Ağı ve Daha Hızlı B-ESA modellerinin katsayıları eşittir. Tek Atışlık Detektörün katsayısı ise diğer modellerin katsayısının 2 katıdır. Deney 11’de sınıf nesnesinin geri çağırma değeri düşüktür. Deney sonuçları Şekil 5.13’te görülmektedir.




Şekil 5.13. Deney 11 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği

Deney 12: Tek Atışlık Detektör ve Daha Hızlı B-ESA modellerinin katsayıları eşittir. Retina Ağı modelinin katsayısı ise diğer modellerin katsayısının 2 katıdır. Deney sonuçları Şekil 5.14’de görülmektedir. Standart katsayılar ile yapılan deneyler içerisinde en başarılı sonuç bu deneyde elde edilmiştir.




Şekil 5.14. Deney 12 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği

Deney 13: Tek Atışlık Detektör ve Retina Ağı modellerinin katsayıları eşittir. Daha Hızlı B-ESA modelinin katsayısı ise diğer modellerin katsayısının 2 katıdır. Bu deneyde elde edilen sonuçlar oldukça dengelidir. Deney sonuçları Şekil 5.15'te görülmektedir.



Şekil 5.15. Deney 13 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği


Deney 14: Bu deneyden itibaren iki modelin aynı anda diğer modele göre iki kat katsayı değerine sahip olmasının toplam başarıya etkileri incelenmektedir. Bu kapsamda; Tek Atışlık Detektör ve Retina Ağı modellerinin katsayıları eşittir ve bu katsayı, Daha Hızlı B-ESA modelinin katsayısının iki katıdır. Deney sonuçları Şekil 5.16'da görülmektedir.



Şekil 5.16. Deney 14 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği

Şekil 5.16 incelendiğinde; deney 11’de olduğu gibi araç sınıfının geri çağırma değeri diğer sınıflara göre nispeten daha düşük bir değerden başlamaktadır. Bu durum, deney 11 ve deney 14’de iki kat katsayıya sahip tek atışlık detektörün araç sınıfı nesnesi tespitinde diğer modellere nazaran daha düşük başarı göstermesidir.


Deney 15: Tek Atışlık Detektör ve Daha Hızlı B-ESA modellerinin katsayıları eşittir ve bu katsayı, Retina Ağı modelinin katsayısının iki katıdır. Deney sonuçları Şekil 5.17’de görülmektedir.



Şekil 5.17. Deney 15 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği


Deney 15'te de iki kat katsayıya sahip tek atışlık detektör kullanıldığı için; deney 11 ve deney 14'de olduğu gibi araç sınıfının geri çağırma değeri diğer sınıflara göre nispeten daha düşük bir değerden başlamaktadır.

Deney 16: Bu deneyde, Retina Ağı ve Daha Hızlı B-ESA modellerinin katsayıları eşittir ve bu katsayı, Tek Atışlık Detektör modelinin katsayısının iki katıdır. Deney sonuçları Şekil 5.18'de görülmektedir.



Şekil 5.18. Deney 16 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği

Deney 17: Katsayı Ağırlıklı topluluk modelinin son deneyidir. Bu deneyde, Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA modellerinin katsayıları, bölüm 4.2’de bahsedilen ortalama kare sapması tekniği kullanılarak optimizasyon tekniği ile hesaplanmıştır. Bu katsayılar ile yapılan deneyde oldukça başarılı sonuçlar elde edilmiştir. Deney sonuçları Şekil 5.19’da görülmektedir.



Şekil 5.19. Deney 17 sonuçları (a) hassasiyet-geri çağırma eğrisi (b) sınıf bazında F1 skoru grafiği

Optimize edilmiş katsayı ağırlıklı topluluk nesne tespit modelinin farklı katsayılar ile yapılan deneylerde elde edilen hassasiyet-geri çağırma eğrisi ve sınıf bazında F1 skoru değerleri daha önce verilmiştir. Çizelge 5.5'te bu deney sonuçlarına göre elde edilen OHO değerlerinin karşılaştırması yer almaktadır. k_1 , k_2 ve k_3 sırasıyla Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA modellerinin katsayı değerleridir.

Çizelge 5.5. Optimize Edilmiş Katsayı Ağırlıklı topluluk nesne tespit modeli OHO sonuçları

Model	OHO
Tek Atışlık Detektör	0.832
Retina Ağı	0.916
Daha Hızlı B-ESA	0.920
Deney 10 ($k_1 = k_2 = k_3 = 1$)	0.931
Deney 11 ($k_1 = 2, k_2 = 1, k_3 = 1$)	0.924
Deney 12 ($k_1 = 1, k_2 = 2, k_3 = 1$)	0.933
Deney 13 ($k_1 = 1, k_2 = 1, k_3 = 2$)	0.930
Deney 14 ($k_1 = k_2 = 2, k_3 = 1$)	0.929
Deney 15 ($k_1 = 2, k_2 = 1, k_3 = 2$)	0.932
Deney 16 ($k_1 = 1, k_2 = 2, k_3 = 2$)	0.927
Deney 17 ($k_1 = 0.0226, k_2 = 0.6527, k_3 = 0.3246$)	0.942

Çizelge 5.5'te de görüleceği üzere en başarılı sonuç, optimize edilmiş katsayılar kullanılarak yapılan deney 17'de elde edilmiştir. Optimize edilmiş katsayılar incelendiğinde tek atışlık detektörün katsayısının diğer 2 modelin katsayısına nazaran neredeyse 0'a yakın olduğu görülmektedir. Bunun nedeni, tek atışlık detektörün araç sınıfı nesnesi tespitinde diğer modellere nazaran daha düşük başarı göstermesidir. Ancak deney sonuçlarından da görüleceği üzere tüm katsayı kombinasyonları, tek başına kullanılan nesne tespit modellerinden daha yüksek başarı elde etmiştir.

5.5. Tez Çalışması Kapsamında Önerilen Modellerin NWPU-VHR10 Veri Seti Kullanan Çalışmalar İle Karşılaştırılması

Tez çalışması kapsamında ortaya koyduğumuz modellerin tarafsız olarak NWPU-VHR10 veri seti üzerindeki performansını değerlendirmek için literatürde aynı veri setini kullanan diğer modeller ile karşılaştırması yapılmıştır. Karşılaştırma sonuçları Çizelge 5.5'te görülmektedir. Koyu renkli ile işaretlenen değerler, sınıf bazında elde edilen en yüksek OH değerleridir. Model1, Geliştirilmiş Daha Hızlı B-ESA; Model 2 ise Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modelidir.

Çizelge 5.6. Farklı modellerin NWPU-VHR10 veri seti üzerindeki performansı

Sınıf / Model	RICNN [19]	DFCNN [28]	FMSSD [29]	RICAO [31]	DODN [32]	CACNN [91]	Model 1	Model 2
Uçak	0.8835	0.9085	0.9970	0.9970	0.9392	0.9991	0.9893	1.000
Gemi	0.7734	0.9011	0.8990	0.9080	0.9297	0.9055	0.9388	0.9780
Yakıt Tankı	0.8527	0.8768	0.9030	0.9061	0.9925	0.9001	0.9413	0.6982
Beyzbol Sahası	0.8812	0.9882	0.9820	0.9291	0.9633	0.9965	0.9644	0.9680
Tenis Sahası	0.4083	0.8950	0.8600	0.9029	0.9612	0.9016	0.9652	0.9310
Basketbol Sahası	0.5845	0.9078	0.9480	0.8013	0.7097	0.9091	0.9515	0.9681
Koşu Pisti	0.8673	0.9062	0.9960	0.9081	1.0000	0.9091	0.9987	0.9970
Liman	0.6860	0.8872	0.7560	0.8029	0.9688	0.8897	0.9698	1.000
Köprü	0.6151	0.9034	0.8010	0.6853	0.8115	0.7962	0.5965	0.9030
Araç	0.7110	0.8773	0.8820	0.8714	0.8009	0.8900	0.8564	0.9340
OHO	0.7263	0.9052	0.9040	0.8712	0.9077	0.9047	0.9231	0.9420

Çizelge 5.6 incelendiğinde, önerilen her iki modelin ayrı ayrı olarak diğer çalışmalara kıyasla daha iyi sonuç verdiği görülmektedir. Diğer çalışmalardan daha iyi performans gösteren DODN modelinden ile karşılaştırıldığında; Geliştirilmiş Daha Hızlı B-ESA modeli %1.71 oranında, Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modeli ise %3,64 daha fazla OHO başarısı elde etmiştir. Bu durumun nedenleri;

- Geliştirilmiş Daha Hızlı B-ESA modelinde,
 - Deforme Edilebilir ESA'nın Standart ESA'ya kıyasla daha fazla alıcı alandan öznitelik çıkartması,
 - ÖPA'nın farklı katmanlardan elde edilen özniteliklerin tespit ağına verilmesi,
 - Paket normalizasyonu yerine ağırlık standardizasyonu kullanılması ile Nvidia TITAN X veya Nvidia TITAN XP gibi çok güçlü GİB'lere nazaran daha zayıf bir GİB olan Nvidia GTX1080 GİB ile eğitim işleminin başarılı olarak sonuçlandırılmasıdır.
- Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modelinde;
 - Nesne tespiti konusunda oldukça başarılı performans sergileyen 3 farklı modelin güçlü özelliklerinin birleştirilmesi,
 - Kullanılan nesne tespit modellerinin en optimal ağırlık katsayıları hesaplanarak önerilen modelin NWPU-VHR 10 veri setine uyumu sağlanmıştır,
 - Her bir nesne tespit modelinin birbirinden bağımsız olarak eğitim işlemine tabi tutulması sonucunda aşırı öğrenme sorunu ile karşılaşılmasıdır.


Geliştirilmiş Daha Hızlı B-ESA modelimiz oldukça iyi bir performansı sağlasa da, köprü nesne kategorisi için tespit doğruluğu hala düşüktür. Bunun nedeni, çalışmada kullandığımız veri setindeki sınıflar arası dengesizliktir. Bu da sonuçlara etki etmiştir. Daha fazla eğitim örneği içeren sınıflarda(örneğin uçak sınıfı) başarı yüksek çıkarken daha az eğitim örneği içeren sınıflarda(örneğin köprü sınıfı) başarı oranı düşmüştür. Veri arttırma işlemi de bu sonucu değiştirmemiştir. Bu sorunun çözümü, sınıflar arası dengesizliğin ortadan kaldırılmasıdır. Gelecek çalışmalarda önerilen bu modelde sınıflar arasındaki dengesizliği ortadan kaldırmak amaçlanmaktadır.

Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modeli, diğer modellerden daha iyi nesne tespit performansı sergilemektedir. Ancak bu modelin de bazı dezavantajları bulunmaktadır. Bunlar; topluluk olarak kullanılan her bir nesne tespit modelinin birbirinden

ayrı olarak eğitim işlemine tabi tutulması zorunluluđu ve kullanılan veri setine göre optimize edilmiş katsayı belirleme işleminin uzun ve yorucu bir süreç olmasıdır. Ancak, nesne tespit performansı göz önüne alındığında bu dezavantajlar kabul edilebilir düzeydedir.

Her iki model ve sınıfa özgü nesne kategorisi sınıflandırıcılarını kullanarak, test veri setimizde on sınıf nesne tespitini gerçekleştirilmiştir. Şekil 5.20 ve 5.21’de doğru pozitif, yanlış pozitif ve yanlış negatiflerin sırasıyla yeşil, kırmızı ve mavi dikdörtgenlerle gösterildiđi önerilen her iki modelin nesne tespit sonuçları gösterilmektedir. Nesnelerin yönleri ve boyutlarındaki büyük deđişikliklere rağmen, hem Geliştirilmiş B-ESA modeli ve Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modeli, nesnelerin çođunu başarıyla tespit etmiştir.





Şekil 5.20 Geliştirilmiş Daha Hızlı B-ESA modelinin NWPU-VHR10 veri seti üzerindeki nesne tespit sonuçları



Şekil 5.21 Katsayı Ağırlıklı Topluluk Nesne Tespit modelinin NWPU-VHR10 veri seti üzerindeki nesne tespit sonuçları

6. SONUÇ

Bu tez çalışmasında uzaktan algılama görüntülerindeki nesne tespiti işleminde yer alan zorlukların giderilmesine yönelik iki yeni nesne tespit modeli önerilmektedir. Bu doğrultuda; uzaktan algılama görüntülerindeki nesnelerin tespiti konusunda yaşanan zorluklar ve çalışmalar, uzaktan algılama kavramı ve modelimizi oluştururken kullanılan tüm yapılar detaylı olarak anlatılmıştır. Böylece tasarlanan modellerin ve üretilen çıktılarının daha anlaşılır olması sağlanmıştır.

Tez çalışmasında ilk olarak, uzaktan algılama resimlerindeki nesnelere tespit etmek için deforme edilebilir evrişim yapısı ile güçlendirilmiş Daha Hızlı B-ESA nesne tespit modeli önerilmektedir. Önerilen modelde kullanılan ÖPA ile düşük çözünürlüklü, semantik açıdan güçlü özellikler ile yüksek çözünürlüklü, semantik açıdan zayıf özellikler birleştirilerek farklı büyüklük ve şekildeki (örneğin köprü ve araba gibi) nesnelerin tespiti başarı ile yapılmıştır. Ayrıca önerilen modelin, tek GİB'li sistemlerde küçük yığın boyutu (GİB başına 1 görüntü) ile daha verimli eğitim yapabilmesi amacıyla, nesne tespit modellerinde sıklıkla kullanılan yığın normalizasyonu tekniği yerine ağırlık standartlaştırma tekniği kullanılmıştır. Böylece, çoklu GİB içeren pahalı sunuculara gerek duymadan ev kullanıcılarının orta-düşük düzey GİB'leri ile eğitim yapabilmelerine olanak sağlanmıştır.

Tez çalışması kapsamında ikinci olarak, literatürde oldukça sık kullanılan ve diğer çalışmalara referans olacak seviyede başarılı olan Tek Atışlık Detektör, Retina Ağı ve Daha Hızlı B-ESA nesne tespit modellerinin ağırlıklı topluluk nesne tespit yapabildiği bir model önerilmektedir. Önerilen modelde, üç nesne tespit modelinin nesne tespitleri giriş olarak alınmakta ve bu nesne tespitleri Ortalama Kare Sapma tekniği kullanılarak optimizasyon işlemine tabi tutulmaktadır. Bu işlem sonrasında ortaya çıkan optimize edilmiş katsayılar ile giriş olarak kullanılan modellerin nesne tespitleri çarpılarak nihai sonuç olarak kullanılacak olan topluluk nesne tespit sonuçları elde edilmektedir. Giriş model sayısı 3 olarak belirlenmiştir ancak istenirse daha fazla nesne tespit modeli giriş olarak kullanılabilir. Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit Modeli bu esnekliği sağlayabilecek şekilde tasarlanmıştır.

Önerilen her iki modelin nesne tespit performansını değerlendirmek için Uzaktan algılama nesne tespiti çalışmalarında oldukça sık kullanılan NWPU-VHR10 veri seti kullanılmıştır. Deneyle aşamasında ilk olarak Geliştirilmiş Daha Hızlı B-ESA modelinin farklı eğitim-test veri seti oranları ile deneyleri yapılmıştır. Bu deneylerin amacı, modelimizin daha az ve ya daha fazla veri ile eğitilmesi sonucunda başarısının ve gürbüzlüğünün tespit edilmesidir. Bu kapsamda; farklı eğitim-test veri seti oranları yapılan 9 deney yapılmıştır. Her bir deney sonucunda; modelin, toplam kayıp – doğruluk eğrisi, hassasiyet-geri çağırma eğrisi ve sınıf bazında F1 skoru grafiği ayrı olarak verilmiştir. Yapılan bu 9 deney sonucunda; veri eksikliğinin performansı doğrudan etkilediği görülmektedir. Bu etki F1 skoru grafiklerinde daha belirgin görülmektedir. Tez çalışmasında önerilen modellerin nesne tespit performansı, veri seti oranlarında önemli değişikliklere rağmen stabil kalmaktadır. Ayrıca deney sonuçlarına göre elde edilen OHO sonuçları çizelge olarak verilerek genel bir çerçeve çizilmiştir.

Deneyle aşamasının ikinci bölümünde; tez çalışması kapsamında ortaya koyulan diğer model olan Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modelinin farklı katsayılar ve optimize edilmiş katsayı değerleri ile deneyleri yapılmıştır (toplam 8 deney). Deney sonuçlarından da görüleceği üzere tüm katsayı kombinasyonları, tek başına kullanılan nesne tespit modellerinden daha yüksek başarı elde etmiştir.

Deneyle aşamasının son bölümünde; tez çalışması kapsamında ortaya konulan her iki modelin tarafsız olarak performansını değerlendirmek için literatürde aynı veri setini kullanan diğer modeller ile karşılaştırması yapılmıştır. Yapılan karşılaştırma detaylı olarak çizelge halinde verilmiştir. Çizelgenin incelenmesi neticesinde; aynı veri setini kullanan güncel modellere göre Geliştirilmiş Daha Hızlı B-ESA modeli %1.71 oranında, Optimize Edilmiş Katsayı Ağırlıklı Topluluk Nesne Tespit modeli ise %3.64 oranında daha fazla nesne tespiti başarısı elde ettiği görülmektedir.

Tez çalışmasında önerilen Geliştirilmiş Daha Hızlı B-ESA modeli, uzaktan algılama görüntülerindeki nesnelere tespitinde oldukça iyi bir performansı sergilese de, bazı nesne kategorileri için tespit doğruluğu hala düşüktür. Bunun nedeni, çalışmada kullanılan veri setindeki sınıflar arası dengesizliktir. Bu da sonuçlara etki etmiştir. Daha fazla eğitim örneği içeren sınıflarda başarı yüksek çıkarken daha az eğitim örneği içeren sınıflarda başarı oranı

düşmüştür. Sınıflar arası dengesizliğin ortadan kaldırılması bu sorunun çözümü olarak görülmektedir.

Gelecek çalışmalarda;

- Geliştirilmiş Daha Hızlı B-ESA modelinin başarısını düşüren sınıflar arasındaki dengesizlik sorununu çözmeye yönelik çalışmaların yapılması,
- Optimize Edilmiş Katsayı Ağırlıklı Nesne Tespit Modelinde, uzun ve yorucu bir süreç olan optimizasyon işlemi sonrasında elde edilen katsayıların, optimizasyon işlemi ile değil de modelin kendi kendine öğrenebilmesi için bir sinir ağının modele eklenmesi amaçlanmaktadır.



KAYNAKLAR

1. Ilie, G., and Vasile, G. (2011). *Spaceborne SAR Tomography: Application in Urban Environment*. Report in Grenoble INP, Fransa, 1-85.
2. Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009, 20-25 Haziran). *ImageNet: A Large-Scale Hierarchical Image Database*. IEEE International Computer Vision and Pattern Recognition (CVPR), Florida, ABD 248-255.
3. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., and Johnson, B. (2019). Deep Learning in Remote Sensing Applications: A Meta-Analysis and Review. *International Society for Photogrammetry and Remote Sensing Journal of Photogrammetry and Remote Sensing*, 152(3), 166-177.
4. Cheng, G., and Han, J. (2016). A Survey on Object Detection in Optical Remote Sensing Images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117(1), 11-28.
5. İnternet : NWPU-VHR10 Veri Seti (2015). URL: <http://www.escience.cn/people/gongcheng/NWPU-VHR-10.html>, Son Erişim Tarihi : 15 Nisan 2019.
6. Jin, X., and Davis, C.H. (2007). Vehicle Detection from High-Resolution Satellite Imagery Using Morphological Shared-Weight Neural Networks. *Image and Vision Computing*, 25(9), 1422–1431.
7. Chen, X., Xiang, S., Liu, C.L., and Pan, C.H. (2014). Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks. *IEEE Geoscience and Remote Sensing Letters*, 11(10), 1797–1801.
8. Jiang, Q., Cao, L., Cheng, M., Wang, C., and Li, J. (2016, 12-16 Mart). *Deep Neural Networks-Based Vehicle Detection in Satellite Images*. International Symposium on Bio-electronics and Bio-informatics, Beijing, Çin, 184-187.
9. Zhou, P., Cheng, G., Liu, Z., Bu, S., and Hu, X. (2016). Weakly Supervised Target Detection in Remote Sensing Images Based on Transferred Deep Features and Negative Bootstrapping. *Multidimensional Systems and Signal Processing*, 27(4), 925–944.
10. Dalal, N., and Triggs, B. (2005, 20-26 Haziran). *Histograms of Oriented Gradients for Human Detection*. IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), Kaliforniya, ABD, 886-893.
11. Zhang, L., Shi, Z., and Wu, J. (2015). A Hierarchical Oil Tank Detector with Deep Surrounding Features for High-Resolution Optical Satellite Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(10), 4895–4909.

12. Krizhevsky, A., Sutskever, I., and Hinton, G. (2012, 3-6 Aralık). *ImageNet Classification with Deep Convolutional Neural Networks*. Neural Information Processing Systems (NIPS), Nevada, ABD, 645 – 651.
13. Salberg, A.B. (2015, 26-31 Temmuz). *Detection of seals in Remote Sensing Images Using Features Extracted from Deep Convolutional Neural Networks*. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Milano, İtalya, 1893-1896.
14. Sevo, I., and Avramovic, A. (2016). Convolutional Neural Network Based Automatic Object Detection on Aerial Images. *IEEE Geoscience and Remote Sensing Letters*, 13(5), 740–744.
15. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015, 7-12 Haziran). *Going Deeper with Convolutions*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, ABD, 1-9.
16. Yang, Y., and Newsam, S. (2010, 3-5 Kasım). *Bag-of-Visual-Words and Spatial Extensions for Land-Use Classification*. International Symposium on Advances in Geographic Information Systems (ACM-GIS), Wuhan, Çin, 270-279.
17. Zhu, H., Chen, X., Dai, W., Fu, K., Ye, Q., and Jiao, J. (2015, 27-30 Eylül). *Orientation Robust Object Detection in Aerial Images Using Deep Convolutional Neural Network*. IEEE International Conference on Image Processing (ICIP), Kuebek, Kanada, 3735-3739.
18. Zhang, F., Du, B., Zhang, L., and Xu, M. (2016). Weakly Supervised Learning Based on Coupled Convolutional Neural Networks for Aircraft Detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5553–5563.
19. Peicheng, Z., Cheng, G., and Junwei, H. (2016). Learning Rotation-Invariant Convolutional Neural Networks for Object Detection in VHR Optical Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3), 7405–7416.
20. Wang, C., Bai, X., Wang, S., Zhou, J., and Ren, P. (2019). Multiscale Visual Attention Networks for Object Detection in VHR Remote Sensing Images. *IEEE Geoscience and Remote Sensing Letters*, 16, 309–314.
21. Long, Y., Gong, Y., Xiao, Z., and Liu, Q. (2017). Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, 55(5), 2486-2498.
22. Li, X., and Wang, S. (2017). Object Detection Using Convolutional Neural Networks in a Coarse-to-Fine Manner. *IEEE Geoscience and Remote Sensing Letters*, 14(11), 2037-2041.

23. ElMikaty, M., and Stathaki, T. (2017) Detection of Cars in High-Resolution Aerial Images of Complex Urban Environments. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10), 5913-5924.
24. Lin, H., Shi, Z., and Zou, Z. (2017) Fully Convolutional Network with Task Partitioning for Inshore Ship Detection in Optical Remote Sensing Images. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1665-1669.
25. Wu, X., Hong, D., Chanussot, J., Xu, Y., Tao, R., and Wang, Y. (2020) Fourier-Based Rotation-Invariant Feature Boosting: An Efficient Framework for Geospatial Object Detection. *IEEE Geoscience and Remote Sensing Letters*, 17(2), 302-306.
26. Ren, S., He, K., Girshick, R., and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149.
27. Dong, R., Xu, D., Zhao, J., Jiao, L., and An, J. (2019) Sig-NMS-Based Faster R-CNN Combining Transfer Learning for Small Target Detection in VHR Optical Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11), 8534-8545.
28. Cheng, B., Zheng-zhou, L., Qingqing, W., Bo, L., Huihui, Y., Lin, Q., and Bo, Q. (2019) Multi-Class Objects Detection Method in Remote Sensing Image Based on Direct Feedback Control for Convolutional Neural Network. *IEEE Access*, 7, 144691-144709.
29. Wang, P., Sun, X., Diao, W., and Fu, K. (2019) FMSSD: Feature-Merged Single-Shot Detection for Multiscale Objects in Large-Scale Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 4(2), 1-14.
30. Zhang, Z., Jiang, R., Mei, S., Zhang, S., and Zhang, Y. (2019). Rotation-Invariant Feature Learning for Object Detection in VHR Optical Remote Sensing Images by Double-Net. *IEEE Access*, 8, 20818-20827.
31. Li, K., Cheng, G., Bu, S., and You X. (2018). Rotation-Insensitive and Context-Augmented Object Detection in Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 56(4), 2337-2349.
32. Wang, C., Shi, J., Yang, X., Zhou, Y., Wei, S., Li, L., and Zhang, X. (2019) Geospatial Object Detection via Deconvolutional Region Proposal Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(8), 1-14.
33. Deng, Z., Sun, H., Zhou, S., Zhao, J., and Zou, H. (2017). Toward Fast and Accurate Vehicle Detection in Aerial Images Using Coupled Region-Based Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3652-3664.
34. Zhang, L., and Zhang, Y. (2017) Airport Detection and Aircraft Recognition Based on Two-Layer Saliency Model in High Spatial Resolution Remote-Sensing Images. *IEEE*

- Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(4), 1511-1524.
35. Chaudhuri, D., Kushwaha, N.K., Samal, A., and Agarwal, R.C. (2016) Automatic Building Detection From High-Resolution Satellite Images Based on Morphology and Internal Gray Variance. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(5), 1767-1779.
 36. Han, X., Zhong, Y., and Zhang, L. (2017) An Efficient and Robust Integrated Geospatial Object Detection Framework for High Spatial Resolution Remote Sensing Imagery. *Remote Sensing*, 9(7), 666 -688.
 37. Chen, S., Zhan, R., and Zhang, J. (2018) Geospatial Object Detection in Remote Sensing Imagery Based on Multiscale Single-Shot Detector with Activated Semantics. *Remote Sensing*, 10(4), 820 – 841.
 38. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., and Reed, S. (2016, 26 Haziran – 1 Temmuz). *SSD: Single Shot Multi Box Detector*. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 47-54.
 39. Liu, Y., Zhang, Z., Zhong, R., Chen, D., and Ke, Y. (2018) Multilevel Building Detection Framework in Remote Sensing Images Based on Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3688-3700.
 40. Körez, A., and Barışçı, N. (2020) Object Detection with Low Capacity GPU Systems Using Improved Faster R-CNN. *Applied Sciences*, 10(1), 83 – 95.
 41. Barut, O. (2018). *Geospatial Object Recognition Using Deep Networks For Satellite Images*, Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 45 – 55.
 42. Zakharova, M. (2017). *Automated Coconut Tree Detection In Aerial Imagery Using Deep Learning*, Yüksek Lisans Tezi, KU Leuven University, Leuven, Belçika, 64 – 67.
 43. Chapman, B.W. (2019). *Object Detection In Low-Spatial-Resolution Aerial Imagery Using Convolutional Neural Networks*, Yüksek Lisans Tezi, Naval Postgrade School, Kaliforniya, ABD, 25 – 29.
 44. Kumar, S., and Hebert, M. (2003, 14 – 17 Ekim). *Discriminative random fields: A discriminative framework for contextual interaction in classification*, International Conference on Computer Vision, Nice, Fransa, 1150-1157.

45. Zhong, P., and Wang, R. (2007) A Multiple Conditional Random Fields Ensemble Model for Urban Area Detection in Remote Sensing Optical Images. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12), 3978 - 3988.
46. Gokaraju, B., Durbha, S., King, R., and Younan, N.H. (2012) Ensemble Methodology Using Multistage Learning for Improved Detection of Harmful Algal Blooms. *IEEE Geoscience and Remote Sensing Letters*, 9(5), 827-831.
47. Roy, M., Routaray, D., Ghosh, S., and Ghosh, A. (2014). Ensemble of Multilayer Perceptrons for Change Detection in Remotely Sensed Images. *IEEE Geoscience and Remote Sensing Letters*, 11(1), 49-53.
48. Yu, Y., and Liu, F. (2018). Aerial Scene Classification via Multilevel Fusion Based on Deep Convolutional Neural Networks. *IEEE Geoscience and Remote Sensing Letters*, 15(2), 287-291.
49. Huang, G., Liu, Z., Van der Maaten, L., and Weinberger, K.Q. (2017, 21 – 26 Temmuz). *Densely Connected Convolutional Networks*. IEEE Computer Vision Pattern Recognition, Honolulu, ABD, 2261-2269.
50. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016, 26 Haziran – 1 Temmuz). *Rethinking The Inception Architecture for Computer Vision*. IEEE Computer Vision Pattern Recognition, Las Vegas, ABD, 2818-2826.
51. Dede, M., Aptoula, E., and Genc, Y. (2019). Deep Network Ensembles for Aerial Scene Classification. *IEEE Geoscience and Remote Sensing Letters*, 16(5), 732 – 735.
52. Jiang, H., Qiu, X., Chen, J., Liu, X., Miao, X., and Zhuang, S. (2019). Insulator Fault Detection in Aerial Images Based on Ensemble Learning with Multi-level Perception. *IEEE Access*, 7, 61797 – 61810.
53. Bouska, P. (2018). *Localization and Counting of Humans Based on Satellite and Aerial Imagery*, Yüksek Lisans Tezi, Çekya Teknik Üniversitesi, Prag, Çekya, 47 – 52.
54. Chianucci, D. (2016). *Detection in Aerial Images Using Spatial Transformer Networks*, Yüksek Lisans Tezi, Kate Gleason College of Engineering, New York, ABD, 18 – 20.
55. Liang, Y. (2019). *Object Detection in High Resolution Aerial Images and Hyperspectral Remote Sensing Images*, Doktora Tezi, Rochester Institute of Technology, New York, ABD, 15 – 20.
56. Bhat, A. (2019). *Aerial Object Detection using Learnable Bounding Boxes*, Yüksek Lisans Tezi, Rochester Institute of Technology, New York, ABD, 20 – 22.
57. Sümbül, G. (2018). *Fine-Grained Object Recognition In Remote Sensing Imagery*, Yüksek Lisans Tezi, Bilkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 12 – 16.
58. Soydaş, M. (2019). *Büyük Ölçekli Uzaktan Algılama Görüntülerinden Derin Öğrenme Teknikleriyle Uçak Tespiti*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 5-9.

59. Önün, F. (2019). *Derin Öğrenme ile Yüksek Çözünürlüklü Hava Görüntülerinde Yolların Tespit Edilmesi*, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ, 1-5.
60. Uslu, F.Ş. (2017). *Topluluk Öğrenmeli Destek Vektör Veri Tanımlaması Yöntemi ile Hiperspektral Görüntülerin Sınıflandırılması*, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 6-9.
61. Hughes, G.F. (1968). On The Mean Accuracy of Statistical Pattern Recognizers. *IEEE Transaction Information Theory*, 14(2), 55-63.
62. Yılmaz, S.(2018). *Topluluk Öğrenme Yöntemini Kullanarak Twitter Verisi Üzerinde Duygu Algılama ve Tanıma*, Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 3-7
63. Ergül, U. (2019). *Classification of Hyperspectral Images With Ensemble Learning Methods*, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 8 -12.
64. Stathaki, T. (2008). *Image Fusion : Algorithms and Applications* (First Edition). ABD: Elsevier Academic Press, 393 – 400.
65. Açarçiçek, A.H. (2015). *Derinlikli Öğrenme ile Konuşmacı Duygu Durumunun Sınıflandırılması*, Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul, 1-3.
66. Ciregan, D., Meier, U., and Schmidhuber, J.(2012, 18 – 20 Haziran). *Multi-column Deep Neural Networks for Image Classification*. IEEE Computer Vision and Pattern Recognition, Rhoe Adası, ABD, 3642-3649.
67. Sergey, I., and Szegedy, C. (2015, 6-11 Temmuz). *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*. The 32nd International Conference on Machine Learning(ICML), Lil, Fransa, 448-456.
68. Yuxin, W., and Kaiming, He. (2018, 10-13 Eylül). *Group Normalization*. 15th European Conference on Computer Vision (ECCV), Münih, Almanya, 742 – 755.
69. Dai, J., Qi, H., Xiong, Y., Li, Y., Zhang, G., Hu, H., and Wei, Y. (2017, 22 – 29 Ekim) *Deformable Convolutional Networks*. Proceedings of IEEE International Conference on Computer Vision, Venedik, İtalya, 764-773.
70. Qiao, S., Wang, H., Liu, C., Shen, W., and Yuille, A. (2019, 6 – 9 Mayıs) *Weight Standardization*. International Conference on Learning Representations, New Orleans, ABD, 345-354.
71. Lin, T., Dollar, P., Girshick, R., Kaiming, H., Bharath, H., and Serge, B. (2017, 21 – 26 Temmuz). *Feature Pyramid Networks for Object Detection*. IEEE International Computer Vision and Pattern Recognition (CVPR), Honolulu, Hawaii, 936-944.
72. Lin, T., Goyal, P., Girshick, R., He, K., and Dollar, Piotr. (2018). Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1(2), 1-10.

73. İnternet: Pascal VOC Veri Seti (2005). URL: <http://host.robots.ox.ac.uk/pascal/VOC/>, Son Erişim Tarihi : 26.04.2018.
74. Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollar, P., and Zitnick, C.L. (2014, 6-12 Eylül). *Microsoft COCO: Common Objects in Context*. European Conference on Computer Vision (ECCV), Zürich, İsviçre, 740 – 755.
75. Deng, J., Dong, W., Socher, R., Li L.J., Li, K., and Fei-Fei, L. (2009, 20-21 Haziran). *ImageNet: A Large-Scale Hierarchical Image Database*. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Kyoto, Japonya, 165-171.
76. Ren, Y., Zhu, C., and Xiao, S. (2018). Small Object Detection in Optical Remote Sensing Images via Modified Faster R-CNN, *Applied Sciences*, 8(5), 813-824.
77. Kaiming, H., Xiangyu, Z., Shaoqing, R., and Jian, S. (2016, 27-30 Temmuz). *Deep Residual Learning for Image Recognition*. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Las Vegas, ABD, 770-778.
78. Ruszczyński, A.(2006) *Nonlinear Optimization* (First Edition). ABD:Princeton University Press, 454 – 480.
79. Lehmann, E.L. and Casella, G.(1998) *Theory of Point Estimation* (Second Edition). ABD:Springer Texts in Statics, 589 -603.
80. İnternet: Mmdetection Toolkit (2017). URL : <https://github.com/open-mmlab/mmdetection> , Son Erişim Tarihi : 24.05.2019
81. İnternet: PyTorch Kütüphanesi (2016). URL: <https://pytorch.org/> , Son Erişim Tarihi : 20.06.2018.
82. İnternet: Python Programlama Dili (1990). URL: <https://www.python.org/> , Son Erişim Tarihi: 15.01.2018.
83. Cheng, G., Han, J., Li, K., Qian, X., Zhou, P., Yao, X., and Hu, X. (2013). Object Detection in Remote Sensing Imagery Using a Discriminatively Trained Mixture Model. *International Society for Photogrammetry and Remote Sensing Journal of Photogrammetry and Remote Sensing*, 85(3), 32–43.
84. Liu, W., Ma, L., Wang, J., and Chen, H. (2019) Detection of Multiclass Objects in Optical Remote Sensing Images. *IEEE Geoscience and Remote Sensing Letters*, 16(5), 791-795.
85. Pang, J., Li, C., Shi, J., Xu, Z., and Feng,H. (2019) R2 -CNN: Fast Tiny Object Detection in Large-Scale Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 5512-5524.
86. Hu, Y., Li, X., Zhou, N.,Yang,L., Peng, L., and Xiao, S. (2019). A Sample Update-Based Convolutional Neural Network Framework for Object Detection in Large-Area Remote Sensing Images. *IEEE Geoscience and Remote Sensing Letters*, 16(6), 947-951.

87. Yang, Z., Liu, Y., Liu, L., Tang, X., Xie, J., and Gao, X. (2019). Detecting Small Objects in Urban Settings Using SlimNet Model. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11), 8445-8457.
88. Lu, X., Zhang, Y., Yuan, Y., and Feng, Y. (2020). Gated and Axis-Concentrated Localization Network for Remote Sensing Object Detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1), 179-192.
89. İnternet: Google Earth (2001). URL: <https://www.google.com/intl/tr/earth/index.html>, Son Erişim Tarihi : 08.02.2020.
90. İnternet: Vaihingen Veri Seti (2017). URL:<http://www2.isprs.org/commissions/comm3/wg4/2d-sem-label-vaihingen.html>, Son Erişim Tarihi : 07.02.2020.
91. Gong, Y., Xiao, Z., Tan, X., Sui, H., Xu, C., Duan, H., and Li, D. (2019) Context-Aware Convolutional Neural Network for Object Detection in VHR Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 58(2), 34 – 44.
92. Cheng, G., Han, J., Zhou, P., and Guo, L. (2014). Multi-class geospatial object detection and geographic image classification based on collection of part detectors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 98(4), 119–132.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KÖREZ, Atakan
 Uyuğu : T.C.
 Medeni hali : Evli
 e-mail : atakan.korez@gazi.edu.tr



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	Gazi Üniversitesi / Bilgisayar Mühendisliği	Devam ediyor
Yüksek lisans	Marmara Üniversitesi / Bilgisayar-Kontrol Eğitimi	2009
Lisans	Marmara Üniversitesi / Bilgisayar-Kontrol Öğretmenliği	2004
Lise	Çukurova Elektrik Anadolu Meslek Lisesi	2000

İş Deneyimi

Yıl	Yer	Görev
2006-Halen	Kara Kuvvetleri Komutanlığı	Subay
2004-2006	Milli Eğitim Bakanlığı	Öğretmen

Yabancı Dil

İngilizce

Yayınlar

- Körez, A., Barışçı, N., Çetin A. and Ergün U. (2020) Weighted Ensemble Object Detection with Optimized Coefficients for Remote Sensing Images. *International Society for Photogrammetry and Remote Sensing International Journal of Geo-Information*, 9(6), 370-385.
- Körez, A. and Barışçı, N. (2020) Object Detection with Low Capacity GPU Systems Using Improved Faster R-CNN. *Applied Sciences*, 10(1), 83 – 95.

3. Krez, A. ve amurcu, A.Y., (2005) Basit bir Mikroişlemci Yapısının Web Tabanlı Çoklu Ortam ile Öğretimi. *The Turkish Online Journal of Educational Technology*, 4(13), 12- 19.
4. Krez, A. Ve Barışçı, N. (2019). *İnsansız Hava aracı (İHA) Görüntülerindeki Nesnelerin Kapsül Ağları Kullanılarak Sınıflandırılması*. 3rd International Symposium on Innovative Approaches in Scientific Studies, Ankara, Türkiye, 34-38.
5. Krez, A. ve Barışçı, N. (2018). *İnsansız Hava aracı (İHA) Görüntülerindeki Yayaların Faster R-CNN Algoritması ile Otomatik Tespiti*. 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies, Ankara, Türkiye, 1-4.
6. Krez, A., amurcu, A.Y., (2004). *Basit bir Mikroişlemci Yapısının Web Tabanlı Çoklu Ortam ile Öğretimi*. 4th International Educational Technology Conference, Sakarya, Türkiye, 67-72.

Hobiler

Basketbol, Futbol, Yüzme



GAZİ GELECEKTİR..