



**ASKERİ GEMİLERİN DERİN ÖĞRENME YÖNTEMLERİ İLE
SINIFLANDIRILMASI**

Onurhan ÇELİK

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2022

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.

Onurhan ÇELİK

07/07/2022

ASKERİ GEMİLERİN DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Onurhan ÇELİK

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2022

ÖZET

Günümüzde gelişen teknolojilerle birlikte otonom sistemler yaygın olarak kullanılmaya başlanmıştır. Ülkemizin üç tarafının denizlerle çevrili olması ve aynı zamanda Akdeniz ve Karadeniz arasındaki boğazlar bakımından denizcilik sistemleri önemli rol oynamaktadır. Bu açıdan deniz güvenliğinin sağlanması, deniz kirliliğinin önlenmesi, Arama Kurtarma operasyonları gibi hem askeri hem de sivil işletmelerin gemilerin otomatik olarak sınıflandırılması konusunda ihtiyaçları bulunmaktadır. Verilerin çoğalmasıyla birlikte bu verileri anlamlandırma da daha çok önem kazanmıştır. Bu büyük verilerle derin öğrenme tekniklerinden evrimsel sinir ağları (ESA) da görsel bilginin analizinde çok iyi sonuçlar vermiştir. Bu çalışmada savunma ve askeri kuvvetlerin sistemlerinde kullanım amacıyla askeri gemilerin derin öğrenme yöntemleri ile sınıflandırılması yapılmıştır. Askeri veriler güvenlik ve istihbarat bilgileri içerdiğinden dolayı genellikle erişilemezdir. Bu yüzden açık kaynaklar kullanılarak bir askeri veri seti oluşturulmuştur. Oluşturulan bu veri seti kullanılarak günümüzün başarılı ESA modelleri ile sınıflandırma yapılmıştır ve sonuçlar literatürde bulunan önceki çalışmalar ile karşılaştırılmıştır.

Bilim Kodu : 92432
Anahtar Kelimeler : Derin öğrenme, gemi, sınıflandırma, evrimsel sinir ağları
Sayfa Adedi : 37
Danışman : Prof. Dr. Aydın ÇETİN

CLASSIFICATION OF NAVAL SHIPS WITH DEEP LEARNING

(M. Sc. Thesis)

Onurhan ÇELİK

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2022

ABSTRACT

Today, with the developing technologies, autonomous systems have been widely used. Maritime systems play an important role in countries surrounded by seas. In this respect, both military and civilian businesses, such as ensuring maritime security, preventing marine pollution, and Search and Rescue operations, have needs for automatic classification of ships. Availability of more data and sophistication in artificial neural networks with deep learning led to a tremendous increase in image classification. In this paper, the classification of naval ships with deep learning for defense and military forces is presented. Access to datasets containing military information is generally inaccessible since they contain security and intelligence information. A new dataset from open sources was created. Then, classification was performed with today's successful CNN models and the results were compared with the previous studies in the literature.

Science Code : 92432

Key Words : Deep learning, ship, classification, convolutional neural networks

Page Number : 37

Supervisor : Prof. Aydın ÇETİN

TEŞEKKÜR

Yüksek lisans eğitimimde ve tez çalışmam süresince bilgisi ve deneyimiyle bana yol gösteren danışman hocam sayın Prof. Dr. Aydın ÇETİN'e, bugünlere gelmemde üzerimde emekleri çok olup tüm hayatım boyunca her koşulda yanımda olan sevgili aileme ve hayatı birlikte paylaştığım, tüm zorlukları birlikte üstesinden geldiğim, çok sevdiğim biricik eşim Nahide KIRAL ÇELİK'e teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	xv
SİMGELER VE KISALTMALAR.....	xvi
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	5
3.YÖNTEM ve ARAÇLAR.....	9
3.1. Sınıflandırma.....	9
3.1.1. Evrişimsel sinir ağları.....	10
3.1.2. VGGNet-16 modeli.....	12
3.1.3. Öğrenme aktarımı ve ince ayarlama.....	13
3.2. Askeri gemi veri seti.....	14
3.2.1. Askeri gemi tiplerinin özellikleri	14
3.2.2. Veri setinin oluşturulması	16
3.2.3. Verilerin ön işleminden geçirilmesi	18
4. DENEYSEL ÇALIŞMA.....	23
5. SONUÇ VE ÖNERİLER	29
KAYNAKLAR	31
EKLER.....	35
ÖZGEÇMİŞ	37

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Literatürdeki benzer çalışmaların özeti	8
Çizelge 3.1. Askeri gemi tipleri veri seti dağılımı grafiği	17
Çizelge 4.1. Hiperparametre değerleri	23
Çizelge 4.2. Tam veri seti için öğrenme aktarımlı modelin sınıflandırma sonuçları.....	25
Çizelge 4.3. Alt veri seti için öğrenme aktarımlı modelin sınıflandırma sonuçları.....	26
Çizelge 4.4. Alt ve tam veri seti için sınıfların F1-skor sonuçları	27
Çizelge 4.5. Sınıflandırma sonuçları.....	28
Çizelge 4.6. Sınıflandırma karşılaştırmaları	28

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Veri seti ve sınıflandırma süreçlerinin akış şeması	10
Şekil 3.2. Evrimsel sinir ağları geleneksel modeli	11
Şekil 3.3. VGGNet-16 mimarisi	12
Şekil 3.4. Modelin eğitim aşamaları	14
Şekil 3.5. Askeri gemi tipleri	15
Şekil 3.6. Gemi ana bölümleri	16
Şekil 3.7. Askeri gemi veri setinden örnek resimler	17
Şekil 3.8. Geminin yönleri	18
Şekil 3.9. Çevrilmiş gemi resmi	19
Şekil 3.10. Sivil ve askeri gemi veri setinden örnek resimler	20
Şekil 3.11. Veri setinin sınıflandırılması	20
Şekil 4.1. Tam veri seti için karmaşıklık matrisi	25
Şekil 4.2. Alt veri seti için karmaşıklık matrisi	26
Şekil 4.3. Alt veri seti için doğruluk oranı - dönem sayısı grafiği	27

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar

ASV

CNN

ESA

ILSVRC

SAR

VGG

Açıklamalar

Autonomous sea Surface Vessels

Convolutional Neural Network

Evrişimsel Sinir Ağları

ImageNet Large Scale Visual Recognition Challenge

Sentetik Açıklıklı Radar

Visual Geometry Group

1. GİRİŞ

Gemilerin tespiti ve sınıflandırılması deniz güvenliğinin ve emniyetinin sağlanması ile diğer denizcilik uygulamaları için (ör. trafik denetlemesi, yasa dışı balıkçılık, deniz kirliliği takibi vb.) kritik öneme sahiptir. Tüm alanlarda olduğu gibi denizcilik alanında da gelişen teknolojiler sayesinde işlenmesi gereken büyük veriler oluşmaktadır. Bu veriler içinde gemilerin sınıflandırılması için kritik görüntüler de bulunmaktadır.

Son yıllarda yüksek teknolojilerin denizcilik sistemlerinde de kullanılması önem kazanmıştır. Deniz güvenliğini geliştirme ve denizlerin gemilerden kirlenmesini önlemek amacıyla imzalanan Hamburg Sözleşmesinde taraf ülkelerin kıyıları civarında denizde tehlike içerisinde bulunan şahıslara yeterli arama kurtarma hizmeti sağlanması için gerekli düzenlemeleri yaparak arama kurtarma planları ve çalışmaları yapmaları istenmiştir [1]. Türkiye de ülke sorumluluklarının yerine getirilmesinin yanı sıra arama kurtarma bölgemizde seyreden deniz ve hava araçlarındaki personele her türlü bilgi ve yardımın ulaştırılması, tehlike anında hayatlarının kurtarılabilmesi, karasularımızın ve arama kurtarma bölgemizin daha güvenli hale getirilebilmesi, ulusal kaynaklarımızın efektif kullanılması, gerekli koordinasyon sağlanarak kurumlar arası işbirliğinin en üst düzeye çıkartılarak, etkin bir arama kurtarma hizmetinin sağlanması amacıyla Türk Arama ve Kurtarma Yönetmeliği oluşturulmuştur.

Oluşturulan yönetmelikte en çok görev Sahil Güvenlik Komutanlığı'na düşmektedir. Sahil Güvenlik Komutanlığı Türkiye Cumhuriyetinin bütün sahillerinde, iç suları olan Marmara Denizi, İstanbul ve Çanakkale boğazlarında, liman ve körfezlerinde, karasularında, Münhasır Ekonomik Bölgesi ile ulusal ve uluslararası hukuk kuralları uyarınca egemenlik ve denetimi altında bulunan deniz alanları ile hükümranlık haklarının korunmasına ilişkin görevler kapsamında uluslararası sularda, uluslararası sözleşmeler çerçevesinde Uluslararası Denizcilik Örgütüne deklare edilen Türk Arama Kurtarma Bölgesinde; deniz güvenliğini, deniz emniyetini, asayiş ve kamu düzenini sağlamak, korumak ve kollamak, suç işlenmesini önlemekle görevli ve yetkilidir. Sahil Güvenlik Komutanlığı, kanunlarla ve uluslararası sözleşmelerle kendisine verilen görevleri ifa eder ve yetkileri kullanır [1].

Bu görevlerin büyük bölümünün temelinde hedeflerin belirlenmesi ve tanımlanması bulunmaktadır. Bu bakımdan Sahil Güvenlik kuvvetlerinin görevleri sırasında hedeflerin kimlik tespitlerinin kolaylaştırılması görevin başarısına yardımcı olmaktadır.

Askeri ve sivil kuvvetlerin gerek kıyı gözetleme merkezlerinde gerekse de hareketli platformlarında kamera ve elektro-optik sistemler bulunmaktadır. Bu sistemlerden alınan görüntülerin işlenerek otomatik olarak algılanması ve sınıflandırılması gerekmektedir.

Karar destek sistemlerinde hedef gemilerin kimliği hakkında bilgi sahibi olmak gerekli durumlar için avantaj getirmektedir. Tespit edilen hedeflerin askeri/sivil olması, eğer askeri bir platformsa platformun tipi, taşıdığı silah ve sensörlere göre tehdit olasılıkları çıkarılabilmektedir. Dolayısıyla platformların üzerindeki elektronik görüntüleme sistemlerinden elde edilen görüntüler yardımıyla bir sınıflandırma yapılması bu analizlere katkı sağlamaktadır.

Günümüzde otonom sistemler hayatımızın her alanında kullanılmaktadır. En önemli kullanım alanlarından biri de askeri ve savunma alanındadır. Otonom sistemlerin gereksinim duyduğu ihtiyaçlar hem insansız platformlarda hem de insanlı platformlarda yeni teknolojiler ile karşılanmaya başlanmıştır. Bu sayede karar aşamalarında ve sonuçlara etki durumunda insan müdahalesi azaltılmıştır.

Büyük veri; çok geniş çapta ve çeşitli türlerde olan ve çok hızlı şekilde büyüyen veriler kümesidir. Bu veriler cihazlardan, sensörlerden, internet üzerinden ve çeşitli uygulamalardan oluşmaktadır. Büyük verilerin işlenmesi ve anlamlandırılması bu verilerin kullanımı için önemlidir. Bu büyük veri kümelerinden bilgiye ulaşmak için yapay zeka teknolojileri kullanılmaktadır. Sağlık, eğitim, savunma ve iletişim gibi birçok alanda yapay zeka teknolojileri kullanılarak uygulama çözümleri oluşturulmaktadır.

Oluşan büyük veri içinde görüntü verileri de bulunmaktadır. Bu görüntülerin insanlar tarafından tek tek anlamlandırılması mümkün değildir. Bilgisayarlar aracılığıyla büyük hacimli görüntüleri ve videoları analiz etmek süreklilik ve performans açısından daha mümkündür.

Görüntü verilerinin sınıflandırılması için yapay zekanın bir alt dalı olan Derin Öğrenme yöntemleri kullanılmaktadır. Derin öğrenme ile birçok görüntü işlemi çözümleri yapılabilmektedir. Bu tez çalışmasında, denizcilik sistemlerine yardımcı olmak amacıyla gemi görüntülerinin sınıflandırılması ele alınacaktır. Daha önce yapılan çalışmalarda sivil gemiler ve bu sivil gemilerden oluşan veri setleri ele alınmıştır. Ancak bu çalışmanın hedefinde askeri sistemler yer almaktadır. Bu yüzden askeri gemi tiplerine göre sınıflandırma yapılacaktır. Askeri gemi görüntülerinin askeri tiplere göre sınıflandırılması için derin öğrenme yöntemleri kullanılmıştır. Askeri tipteki gemilerin görev amaçlarına göre dış yapısal özellikleri çeşitlilik göstermektedir. Bu yapısal farklılıkların uygulanacak derin öğrenme yöntemlerinde etkisi de bu tezde araştırılacaktır. Uygulanacak derin öğrenme yöntemlerinin literatürde görüntü sınıflandırma için çok başarılı olduğu kanıtlanan ESA modeli kullanılarak çalışma yapılmıştır.

Derin öğrenme modellerinin eğitiminde büyük verilere ihtiyaç duyulmaktadır. İlk olarak veri setinin hazırlanması gerekmektedir. Askeri alandaki veriler birçok istihbarati bilgi içermesinden dolayı açık kaynak olarak ulaşılamamaktadır. Bu yüzden tez kapsamında çeşitli çevrimiçi kaynaklardan veri seti oluşturularak sınıflandırma çalışmalarında kullanılmıştır. Bu veri seti gelecekte yapılacak diğer çalışmalar için de kullanılabilir olarak literatüre kazandırılacaktır.

Tezin ilerleyen kısımlarında 2. bölümde benzer konudaki çalışmalar ve araştırmalar incelenmiştir. Daha sonra 3. bölümde kullanılan model hakkında bilgi, veri setinin oluşturulması ve ön işlemlerden geçirilmesi anlatılmıştır. 4. bölümde çalışmanın deney aşamasına geçilmiştir. Son olarak 5. bölümde sonuçlar ve öneriler bölümü bulunmaktadır.

2. LİTERATÜR TARAMASI

Bu bölümde tez çalışmasında ele alınan gemi görüntülerinin sınıflandırılmasına yönelik benzer çalışmalardan bahsedilecektir. Tez çalışmasında askeri gemilerin sınıflandırılması ele alınmıştır ancak literatürdeki çalışmalar daha çok sivil veya sivil ağırlıklı gemi sınıflandırılmaları üzerine olduğu görülmüştür.

Gemilerin üst yapı moment değişkenlerine göre sınıflandırılması çalışmasında [2] gemilerin üst yapısına dayanan Ters Sentetik Açıklıklı Radar (ISAR) görüntüleri kullanılmıştır. Üst yapı moment değişmezleri özneteliğini çıkarmak için Hu Momentleri kullanılmıştır. Hu Moment nesne tanıma uygulamaları için bilinen en etkili açıklayıcı özellik çıkartılmasını sağlayan algoritmadır. Uçaklarda, gemilerde ve yer hedeflerinde geniş şekilde uygulanmaktadır. Çalışmada 5 farklı gemi sınıfı için 350 ISAR görüntüsü kullanılmıştır. Çalışmadaki amaç moment değişkenlerine göre fiziksel özelliklerin sınıflandırmaya katkısını değerlendirmektir. Sonuç olarak hu moment algoritmasının gemi sınıflandırmasında etkili olduğu görülmüştür.

Sentetik Açıklıklı Radar (SAR) kaynaklı uydu görüntülerinden derin öğrenme mimarisi YOLOv2 modeli ile bir gemi tespit çalışmasında [3], SAR kaynaklarından alınan görüntülerin çözünürlüğünün düşük olması ve geminin eksik görünümü nedeniyle sadece gemi tespiti üzerinden çalışma yapılmıştır. Kullanılan model ile %90,05 doğruluk oranı elde edilmiştir. Daha önceki Fast-R-CNN modelinden 5,8 kat daha hızlı algılama hızı sağlanmıştır.

Google Earth üzerinden oluşturulan veri seti ile ESA modeli kullanılarak gemi tespit ve sınıflandırma çalışması yapılmıştır [4]. Bu görüntüler SAR görüntüleri gibi yukarıdan gelen gemileri göstermektedir ancak daha yüksek görüntü kalitesine sahiptirler. Bu nedenle sınıflandırma için SAR görüntülerine göre daha uygun bir veri setidir. İki aşamalı sınıflandırma yapılmıştır. İlk aşamada gemi ve gemi olmayan şeklinde iki sınıflı sınıflandırma yapılmıştır. Burada ESA modeli olarak dört evrişim katmanı, üç katmanlı maks-pool ve tam bağlantı katmanı ile iki sonuçla softmax sınıflandırmasını gemi algılama için yapılmıştır.

Çalışmada [4] %99 tespit doğruluğu ve %95 sınıflandırma doğruluk oranlarını elde edilmiştir. Bu doğruluk oranlarına göre derin öğrenme yöntemi olarak ESA'nın gemi sınıflandırmasında olduğu gibi özellik çıkarımı ve öğrenimi için başarılı bir model olduğu görülmüştür.

Çevrimiçi web sitelerinden rastgele seçilen gemi görüntüleri ile bir veri seti oluşturularak bir çalışma yapılmıştır [5]. Bu veri seti üzerinde ESA modeli olan AlexNet'e göre iki kat daha küçük olan bir model kullanarak gemi tiplerine göre sınıflandırma çalışmaları yapılmıştır. Parametrelere göre değişen iki farklı konfigürasyona sahip modeller oluşturulmuştur. İlk konfigürasyondan %80,91, ikincisinden ise %95,43 başarı oranı elde edilmiştir.

Otonom deniz üstü gemilerinde kullanılmak üzere bir çalışma [6] yapılmıştır. ASV'ler diğer gemileri hem gündüz hem de gece uluslararası deniz trafik kurallarına göre sınıflandırmak zorundadır. Öncelikle 9 günlük bir kayıt sonucunda veri seti oluşturulmuştur. Oluşturulan veri setinde 6 gemi tipi ve 2865 resim bulunmaktadır. Daha sonra bu veri setindeki resimler ESA modeli olan VGGNet16 ve Gnostic field algoritması ile sınıflandırma yapılmıştır. Gece ve gündüz olarak ayrılan veri setinden %87,4 doğruluk oranı elde edilmiştir.

Üç boyutlu gemi modellerinin silüet görüntülerinden gemi hatlarının çıkarılması ve optik görüntülerden gemi tanıma çalışması [7] yapılmıştır. Bu çalışmada sentetik veri tabanı oluşturulmuştur. Bu veri seti üzerinde segmentasyon ve yapay sinir ağları kullanarak gemilerin tanıma ve sınıflandırmaları yapılmıştır.

Büyütme ve transfer öğrenme teknikleri ile gemi sınıflandırması yapılan çalışmada [8] VGG-19 model ağı kullanılarak %78'lik bir doğruluk oranı elde edilmiştir.

Gemi sınıflandırmasını gerçekleştirmek için Inception ve ResNet mimarilerine dayalı önceden eğitilmiş ESA modeli Inception kullanılan bir çalışma yapılmıştır [9]. Sınırlı gemi görüntüsüne sahip veri seti üzerinde transfer öğrenme deneyleri yapılmıştır. Optimal çözüm olarak %78,73 doğruluk oranı verilmiştir.

Bu çalışmada [10] gemi görüntülerini içeren açık erişimli MARVEL adında bir veri seti oluşturulmuştur. Oluşturulan veri seti 109 tipte 2 milyon civarında gemi görüntüleri içermektedir. Bu veri setini çevrimiçi Shipspotting web sitesinde bulunan rastgele görüntüler gemiler için tekil bir numara olan IMO numaralarıyla birlikte oluşturulmuştur. Bu veri seti aracılığıyla gemi sınıflandırma, doğrulama ve tanıma çalışmaları yapılabilmektedir.

Çalışmada [10] kullanmak için MARVEL veri setinin sınıflar arası daha dengeli bir alt veri seti oluşturulmuştur. Daha yoğun veri içeren sınıflar için yarı otomatik kümeleme ile 26 sınıf oluşturulmuştur. Çalışmadaki bu alt veri kümesi 140 000 görüntü içermektedir. ESA modeli olan AlexNet kullanılarak yapılan sınıflandırma çalışması sonucunda %73 doğruluk oranına ulaşılmıştır.

Bu çalışmada [11], imge sınıflandırmasında derin öğrenme modellerinden VGGNet-16 kullanılarak kedi ve köpek resimlerinden oluşan bir veri seti eğitilmiştir. Çalışmada VGGNet-16 için düz şekilde bir sınıflandırma çalışması yapılmıştır ve %72,40'lık doğruluk oranı elde edilmiştir. Ardından iki aşamalı sınıflandırma çalışması daha yapılarak sınıflandırma sonucunun değişimi gözlemlenmiştir. Öğrenme aktarımı kullanılarak daha önceden eğitilmiş ağırlıkları kendi veri seti üzerinde test edilmiştir. Öğrenme aktarımı ve ince ayar uygulanan çalışmada başarı oranı %95,40'a kadar çıkmıştır.

SAR görüntülerinden transfer öğrenmesi teknikleri ile daha iyi bir sonuç alınması için bir çalışma yapılmıştır [12]. ESA mimarilerinden ResNet50'ye dayalı olarak yapılan çalışmada SAR görüntülerinden bir test verisi oluşturularak dört sınıflı bir sınıflandırma çalışması yapılmıştır. Çalışmada %83,80'lik bir doğruluk oranına ulaşılmıştır.

YOLOv2 ve YOLOv3'e dayalı olarak geliştirilen ESA modeli ile yedi gemi tipini içeren veri seti üzerinde sınıflandırma çalışması yapılmıştır [13]. Çalışmada önerilen model sınıflandırmadaki hız ve doğruluk oranları YOLO modellerine göre daha iyi sonuç verdiği görülmüştür.

Çizelge 2.1’de literatürdeki benzer çalışmalarda kullanılan sınıflandırma metotları ve veri içeriklerine dair bilgiler bulunmaktadır. Çalışmaların genellikle sivil ağırlıklı olarak optik kamera veya SAR görüntüleri üzerinden yapıldığı görülmektedir.

Çizelge 2.1. Literatürdeki benzer çalışmaların özeti

Çalışma	Sınıflandırma metodu	Veri kaynağı	Veri seti içeriği
[2]	Hu Moment algoritması	SAR	Sivil
[3]	YOLOv2	SAR	Sivil
[4]	Dört evrişim katmanlı ESA modeli	Google Earth	Sivil
[5]	Konfigüre edilmiş AlexNet (FC6 - FC7)	Optik kamera	Sivil + 1 askeri genel tip
[6]	VGGNet16 + Gnotic Field algoritması	Optik kamera	Sivil
[8]	VGGNet-19	Optik kamera	Sivil + Askeri
[9]	Inception	Optik kamera	Sivil + Askeri
[10]	AlexNet	Optik kamera	Sivil + Askeri
[12]	ResNet50	SAR	Sivil
[13]	YOLO + ESA	Optik kamera	Sivil

3. YÖNTEM ve ARAÇLAR

Derin öğrenme temelindeki çalışmalarda çalışmanın ihtiyaç duyacağı kapsamlı veri setinin bulunması çalışmanın başarılı olarak sonuçlanmasındaki en önemli etkidir. Bu yüzden ilk aşamada veri seti hazır hale getirilmelidir. Hazır bir veri seti bulunamadığı için bu tez çalışmasına özel bir veri seti hazırlanacaktır. Çalışmanın amacına yönelik hazırlanacak veri setinin kategorileri belirlenerek uygun veriler veri setine dahil edilecektir.


Veri seti farklı kaynaklardan alınan farklı biçimdeki görüntülerden oluşacaktır. Bu yüzden elde edilen görüntülerin sınıflandırma öncesi ön işlemden geçirilmeleri gerekebilmektedir. Çalışmanın uygulama olarak kullanılması hedeflenen sistemlere sahip platformların oluşturacağı görüntüler istenen özelliklerde olacağı için görüntülerin ön işlemden geçirilmesine ihtiyaç olmayacaktır.

Çalışmada veri setinden sonra sınıflandırma çalışması için kullanılacak derin öğrenme modelinin belirlenmesi gerekmektedir. Görüntü işlemede birçok sınıflandırma modelleri kullanılmıştır. Ancak her model her veri seti için iyi bir sonuç vermemektedir. Bu yüzden daha önce yapılan gemi görüntüleri ile yapılan çalışmalarda başarılı olmuş veri modelleri literatürde araştırılmıştır. Bu sonuca göre uygun veri modelleri belirlenmiştir.

3.1. Sınıflandırma

Gemi resimlerinin sınıflandırılma çalışmasında kullanılan ağ modelleri bu bölümde anlatılmıştır. Yapay zeka teknolojilerinin gelişmesi sonrasında çok katmanlı yapay sinir ağları geliştirilmiştir. Bu çalışmada da veri setine uygun olarak belirlenen ESA modeli ve model üzerinde yapılan ayarlamalar ile sınıflandırma çalışması gerçekleştirilmiştir.

Şekil 3.1 veri seti oluşturma ve sınıflandırma süreçlerinin akış şemasını göstermektedir.




Şekil 3.1. Veri seti ve sınıflandırma süreçlerinin akış şeması

3.1.1. Evrimsel sinir ağları

Derin öğrenme; dijital sistemlerin verilere dayalı olarak öğrenmesini ve kararlar almasını sağlayan yapay zekanın alt dalı olan makine öğrenmesi yöntemidir [14]. Birden fazla katmandan oluşan bir mimari modeli olan derin öğrenmenin bir alt dalı olan ESA ise genellikle görsel bilginin analiz edilmesinde kullanılmaktadır. ESA'lar ile resim üzerindeki objenin hatlarına göre bir çıkarım yapılarak sınıflar arası farklar oluşturulur. Burada benzerlik oranına göre ilgili resim ögesinin sınıfı belirlenir.

ESA mimarisi [15,16] giriş görüntüsü üzerinden evrişim katmanları (Convolution), ortaklama katmanları (Pooling) ve tam bağlantı (Fully-Connected) katmanları adındaki ara katmanların farklı sayıdaki kombinasyonlarından oluşur ve sonucunda bir çıkış yani sonuç katmanı içerir. Şekil 3.2'de geleneksel olarak bir ESA modelinin örneği bulunmaktadır.



Şekil 3.2. Evrişimsel sinir ağı geleneksel modeli


Evrişim katmanında giriş olarak verilen resmin özellikleri algılanır. Verilen çekirdek filtre boyutuna göre resim taranarak resmin daha alt boyutunda öznitelik verileri oluşturulur. Ortaklama katmanı, evrişim katmanları arasında kullanılır ve örnekleme işlemi yapılır. Maksimum veya ortalama değere göre bir ortaklama işlemi gerçekleştirilir. Ortaklama katmanında evrişim katmanında algılanan özellikler korunurken hesaplama boyutu sonraki katmanlar için indirgenir. Bu sayede modelin aşırı ezberleme sorunu önlenir ve hesaplama açısından verimlilik artar. Tam bağlantı katmanında önceki katmanların sonuçları düz bir vektör haline yani tek boyuta indirgenir. Sınıf sonuçları hesaplanarak çıkış katmanına bağlanır.

Ayrıca ana modelde görünmeyen ancak evrişim ve tam bağlantılı katmanlardan sonra kullanılan aktivasyon fonksiyonları da bulunmaktadır. Aktivasyon fonksiyonları doğrusal olmamaları ile ağı öğrenmesi amaçlanmaktadır. En çok kullanılan aktivasyon fonksiyonu ise düzeltilmiş doğrusal birim (ReLU) fonksiyonudur.

ESA mimarilerinde yakın zamanda nesne tanımda öncü olan AlexNet modeli ile Krizhevsky ve ark. 2012 yılındaki ImageNet yarışmasını kazanmışlardır [17]. Bu model ile ESA mimarilerine yeni yaklaşımlar gelmiştir. 5 evrişim ve 3 tam bağlantı katmanı olmak üzere 8 ana katmandan oluşmaktadır. Aktivasyon fonksiyonu sayesinde hesaplama performansı artarken gizli katman olarak dropout kullanımıyla ağı ezberlenmesi önlenmiştir.

3.1.2. VGGNet-16 modeli

Tez çalışmasında sınıflandırma için Şekil 3.3’de katmanlı mimarisi gösterilen VGGNet-16 modeli kullanılmıştır. Literatürdeki son araştırmalar, gemi sınıflandırmasında en etkili modelin VGGNet-16 modeli olduğunu göstermektedir. VGGNet, Simonyan ve Zisserman tarafından önerilen bir evrişimsel sinir ağı modelidir [18]. Model, 2014 yılında ILSVR (Imagenet) [19] yarışmasını kazanmıştır. Imagenet, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri setidir [20]. Bu veri seti üzerinde VGGNet16 modeli ile yaklaşık olarak %92.7’lik test doğrulama sonucuna ulaşmışlardır. Bu sonuçla da daha önceki AlexNet modeline göre daha iyi bir skora erişmişlerdir.



Şekil 3.3. VGGNet-16 mimarisi

VGGNet modelinde AlexNet’e göre en büyük fark büyük boyuttaki filtreler (7x7, 11x11) yerine birden fazla sabit olan 3x3 boyutundaki filtreler kullanılmıştır. Modelin farklı katman sayılarına göre isimlendirmeleri VGGNet-16 ve VGGNet-19 olarak değişmektedir. VGGNet-16, ağırlıkları olan 16 katmana sahiptir. Ağın 13 evrişim katmanı ve ardından 3 tam bağlantılı katmanı vardır. Evrişim katmanları yukarı/aşağı ve sol/sağ olarak 3x3 boyutunda filtreleme işlemleri bulunmaktadır. Ayrıca AlexNet’in eğitim süresini kısaltan ReLU birimleri de kullanılmaktadır. ReLU düzeltilmiş doğrusal birim aktivasyon işlevi anlamına gelir. Girdi pozitif ise doğrusal olarak sonuç verilir, negatif ise sonuç sıfırdır. Bu katman sayesinde ağın daha hızlı öğrenmesi sağlanır.

Model giriş boyutu olarak tutarlılığı sağlamak amacıyla 224x224 piksellik kırpma işlemi uygulanmaktadır. Son katmanlar olan 3 adet tam bağlantılı katmanların ilk ikisi 4096 kanal ve üçüncüsü de sınıf sayısına bağlı değişen kanal sayısına sahiptirler. Ayrıca tüm gizli katmanlar ReLU kullanılmaktadır.

3.1.3. Öğrenme aktarımı ve ince ayarlama


Öğrenme aktarımı [21] ile önceden eğitilmiş bir modelin ağırlıklarını kendi modelimizde kullanabiliriz. Bu sayede ağıın sıfırdan eğitimi ve alt seviye katmanlardaki ortak yapılan işlemlerin tekrarı gerekmez [22,23]. Çünkü genellikle ESA'ların ilk katmanlarında sadece kenarlar ve genel görüntü özellikleri çıkarılmaktadır. Yalnızca son birkaç katmanın kendi verilerimizle ve daha az veri ile eğitilmesi ile öğrenme tamamlanır.

VGGNet-16 modeli için genellikle 1000 sınıftan yaklaşık 1 200 000 veriden oluşan ImageNet veri seti ile yapılmış ve kaydedilmiş ImageNet ön eğitilmiş ağırlıklar kullanılır. Bu ağırlıkların kullanılacağı veri setinin de ImageNet veri setine benzer olması gerekmektedir.

Bu öğrenme aktarımı kullanımında kendi veri setimizin eğitim sırasında son birkaç katmanın eğitimi yapılmaktadır [24]. Bu katmanlarda öğrenme oranı gibi parametreler üzerinde değişiklikler yaparak ağıın en iyi öğrenme koşulu bulunur. Bu aşamaya ince ayarlama denmektedir.

Bu çalışmada Simonyan ve Zisserman'ın ImageNet yarışması için yapılmış Caffe modelinin [25] TensorFlow uyumlu olarak dönüştürülmüş ağırlıkları kullanılmıştır. Şekil 3.3'te görülen VGGNet-16 mimarisinin son iki Tam Bağlantı (Dense) katmanları için ince ayarlama yapılarak sınıflandırma yapılmıştır. Çalışmanın ayrıntılı ağ modeli Ek-1'de verilmiştir. Burada son iki tam bağlantı katmanı FC-7 ve FC-8 katmanlarında Adam Optimizer kullanılmıştır.

Şekil 3.4'te öğrenme aktarımı öncesi ve sonrasında ağın öğrenimine dair aşamalar yer almaktadır.




Şekil 3.4. Modelin eğitim aşamaları

3.2. Askeri gemi veri seti

Bu bölümde askeri tipteki gemilerin yapısal özelliklerinden ve veri setinin oluşturulması ve verilerin ön işlemden geçirilmesiyle ilgili süreçler anlatılmıştır. Askeri gemi veri setinin oluşturulmasında ana tipler esas alınmıştır ve çalışmada da bu tipler kullanılmıştır.

3.2.1. Askeri gemi tiplerinin özellikleri


Askeri gemilerin başlıca tipleri Şekil 3.5'de gösterilmiştir. Bu şekilde olduğu gibi gemilere yandan bakıldığında gemi tiplerine göre değişkenlik gösteren ve gövde üzerinde bulunan üst yapılar (anten, silah, direk, radom, huni vb.) görülmektedir. Bu üst yapıların gemiler üzerinde farklı sayıda, farklı konumlarda ve büyüklüklerde bulunma durumları askeri gemilerin sınıflandırılmasında kullanılabilmektedir.



Şekil 3.5. Askeri gemi tipleri [26]

Geminin temel hattının önceki benzer çalışmalarda kullanılan SAR görüntülerinden ayırt etmek çok zor olsa da günümüzün modern kamera ve elektro-optik sistemleri sayesinde üst yapı özelliklerinin daha detaylı olarak gösterilmesi bu yapıların tanımlanmalarının yapılmasını çok daha kolay hale getirmektedir.

Gemilerin üst yapılarındaki ana bölümler farklı tipteki gemilerde değişkenlik göstermektedir. Tek adalı, merkez adalı, ikiz adalı ve gömmeli olmak üzere dört farklı ana bölüm yapısı bulunmaktadır. Bu ana bölümlere ait örnekler Şekil 3.6'da gösterilmiştir. Bu ana bölümler gemilerin görev amaçlarına göre farklı alt yapıları içermektedir. Ana bölümler ve buna bağlı alt yapılara göre gemi tiplerinin özellik çıkarımında farklılıklar oluşmaktadır. Bu sayede sınıflar ayrıştırılabilmektedir.



Şekil 3.6. Gemi ana bölümleri [26]


3.2.2. Veri setinin oluşturulması

Daha önceki benzer çalışmaların veri setleri ağırlıklı olarak sivil gemi kategorilerini içermekteydi. Bu nedenle de bu çalışmalarda sivil gemiler üzerinde sınıflandırma çalışmaları yapılmıştı. Bu tez çalışmasında sivil gemilere göre daha çok askeri gemilerin sınıflandırmasına odaklanılmıştır. Bu amaçla ilk olarak askeri gemi görüntülerini içeren yeni bir veri seti oluşturulmuştur.

Veri seti çoğunluğu çevrimiçi Shipspotting web sitesinden [27] olmak üzere Wikipedia web sitesinin donanma gemi türleri bölümündeki [28] görüntülerden oluşturulmuştur. Oluşturulan veri seti, 7 farklı gemi tipi için toplam 41 426 görüntü içermektedir. Askeri veri setindeki sınıf tipleri uçak gemisi, muhrip gemi, fırkateyn, çıkarma gemisi, mayın gemisi, karakol gemisi ve denizaltı gemisinden oluşmaktadır. Bu tipler askeri gemilerin ana tipleri olduğu için birbirleri arasında yapısal farklılıklar bulunmaktadır. Korvet veya gambot gibi ana tiplerden üretilmiş alt gemi tiplerinde bu farklılıklar azalmaktadır. Bu yüzden sınıflandırmaya sadece ana tipler dahil edilmiştir.

Hazırlanan askeri gemi veri setinin tip bazlı dağılımı Çizelge 3.1’de gösterilmiştir. Sınıf dağılımları ortalama olarak birbirine yakındır ancak uçak gemisi tipi ortalamadan biraz daha düşüktür.

Çizelge 3.1. Askeri gemi tipleri veri seti dağılımı grafiği




Veri setindeki tiplere göre örnek görüntüler ise Şekil 3.7’de gösterilmiştir. Örnek görüntülerde gemilerin yan hat görünüşleri verilmiştir.



Şekil 3.7. Askeri gemi veri setinden örnek resimler

3.2.3. Verilerin ön işlemden geçirilmesi

Gemilerin ana gövde bölümleri Şekil 3.8’de gösterilmiştir. Veri setindeki gemi görüntüleri gemilerin farklı açılarını içermektedir. Verilerin alındığı kaynaklarda resimlerin çekim açısı ve gemi yönleri yer almadığından alt veri seti oluştururken gemilerin seçilmesi ve çevrilmesi için de sınıflandırma yöntemleri kullanılmıştır. Eğer bu görüntüler askeri platformların sensörleri aracılığıyla elde edilip, görüntüler bu özellikler ile birlikte oluşturulsaydı yön bilgilerine de ulaşılabilirdi. Bu durumda gemi görüntülerinin açığa göre dönüştürülmesi tam olarak yapılabilirdi. Hem de veri setinin tamamı bu ön işlem sonrasında kullanılabilirdi.




Şekil 3.8. Geminin yönleri

Oluşturulan tam veri setinde açı bilgisi olmadığı için bir alt veri seti hazırlanarak gemilerin sadece yan görünümünden (iskele ve sancak tarafından görünümü) alınan görüntüler ve diğer görüntüler (baş ve arka) olmak üzere iki kategoriye ayrılmıştır. Bunun sonucunda yandan görünüme sahip resimlerden oluşturulan yaklaşık 18000 resim içeren alt veri seti oluşturulmuştur.

Alt veri setindeki gemi görüntüleri gemilerin yan tarafından çekilen ve gemiler için özelliklerinin çıkartılmasında tip sınıflandırmasına daha uygun görüntülerdir. Ön ve arka görünümdeki gemi resimlerinde yapısal özelliklerin ayrıştırılması daha zor olmaktadır.

Aynı zamanda bu alt veri seti üzerinde Şekil 3.9’de gösterildiği gibi gemilerin aynı yönden bakması için resimler üzerinde çevirme işlemi uygulanmıştır. Resimler üzerinde uygulanan çevirme işlemi sayesinde evrişimli katmanlarda çıkarılan resim üzerindeki objelerin özelliklerinde tutarlılık sağlanması amaçlanmıştır. Aynı yöne bakan aynı tipteki gemi resimlerinin bulunması öğrenme sonuçlarını doğrudan etkilemektedir.



Şekil 3.9. Çevrilmiş gemi resmi


Çalışmada askeri gemilerin sınıflandırılması sırasında öncelikle geminin askeri ya da sivil bir gemi olduğunun belirlenmesi için sivil gemilerin de olduğu ortak bir veri seti oluşturulmuştur. Bu veri seti hazır veri setlerinden alınan sivil gemiler ve bu çalışmada oluşturulmuş askeri gemilerden alınan görüntülerle oluşturulmuştur. Veri setinden örnek görüntüler Şekil 3.10’da bulunmaktadır.

Bu ortak veri seti üzerinde askeri ya da sivil olarak iki sınıflı bir sınıflandırma çalışması yapılmıştır. Daha sonra da askeri olarak belirlenen gemi resimleri askeri gemi tipleri sınıflandırılmasına dahil edilmiştir.



Şekil 3.10. Sivil ve askeri gemi veri setinden örnek resimler

Şekil 3.11’de askeri ve sivil tipte sınıflandırmaya ait ağaç yapısı görülmektedir. Askeri tip olarak belirlenen resimler için geminin hangi alt tipe ait olduğu belirlenmektedir.



Şekil 3.11. Veri setinin sınıflandırılması

Askeri gemiler ülkelerin donanma kuvvetleri tarafından kullanılan gemi veya botlara verilen genel isimlerdir. Taşıdıkları silah ve sensör sistemleriyle sivil gemilere göre yapısal farklılıklar göstermektedirler. Sınıflandırmada askeri veya sivil gemi olarak ayrıştırmada bu özellikler kullanılmıştır. Daha sonrasında askeri olarak belirlenen gemiler için üst yapı görünüm ve taşıdıkları sistemlere göre ayrıştırılmıştır.

4. DENEYSEL ÇALIŞMA

Modelin deneysel çalışmaları ve eğitimleri GPU (NVIDIA Tesla K80) ile bulut hizmeti veren Google Colab üzerinde gerçekleştirilmiştir. İlgili algoritma ve uygulama yazılımları Python versiyon 3.7 programlama dilinde yazılmıştır. ESA model kullanımları için TensorFlow versiyon 2.7 kütüphanesi [29] kullanılmıştır.

Daha önceki çalışmalarda hiperparametreler göz önüne alındığında, sınıflandırma için 0,0001 öğrenme oranına sahip bir Adam Optimizer kullanılmıştır. Veri paketi boyutu ve seyreltme değeri sırasıyla 128 ve 0,5 olarak ayarlanmıştır. Her sınıflandırma çalışmasında maksimum 10 dönem sayısı tercih edilmiştir. En iyi sonuçlar 10 dönem sayısından önce alınmıştır. Çizelge 4.1’de kullanılan hiperparametreler tablo olarak gösterilmiştir.

Çizelge 4.1. Hiperparametre değerleri

Hiperparametreler	Değer
Öğrenme Oranı	0,0001
Alt	7
Veri Paketi Boyutu	128
Seyreltme Değeri	0,5
Dönem Sayısı	10
Toplam Parametre Sayısı (7 sınıf)	14 890 311

Yapılan sınıflandırma sonuçlarının karşılaştırılmasında değerlendirme ölçütleri olarak doğruluk oranı, kesinlik ve duyarlılık ve F1-skor değerleri kullanılmıştır. Bu değerlere göre yapılan çalışmaların sonucu tartışılmıştır. Doğruluk oranı eğitim verisi ile modelin öğrenmesinin ardından test verilerinin ne sıklıkta doğru tahmin edildiğinin oranını vermektedir. Sadece doğruluk oranı sonucuyla modelin sınıflar bazında başarısını değerlendirmek yetersiz olduğu için diğer ölçütler de hesaplanmıştır. Aynı zamanda sınıflar arası eşit bir veri dağılımı olmadığı için F1-skor değerinin de göz önüne alınması bu açıdan önemli olmaktadır.

Değerlendirme ölçütlerinin hesaplanmasında dört farklı sonuca göre işlemler yapılmıştır. Bunlar gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif sonuçlarıdır. Yapılan tahminde doğru şekilde pozitif tahmin için gerçek pozitif (GP), doğru şekilde yapılan negatif tahmin için gerçek negatif (GN), yanlış şekilde yapılan pozitif tahmin için yanlış

pozitif (YP) ve yanlış şekilde yapılan yanlış tahmin için ise yanlış negatif (YN) olarak yorumlanmaktadır. Değerlendirme ölçütlerinin hesaplanmasında aşağıdaki formüller kullanılmıştır.

$$\text{Doğruluk Oranı} = \frac{GP+GN}{GP+GN+YP+YN}$$

$$\text{Kesinlik} = \frac{GP}{GP+YP}$$

$$\text{Duyarlılık} = \frac{GP}{GP+YN}$$

$$\text{F1-skor} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Sınıflandırma çalışmasında ilk olarak tüm veri setinin ön işleminden geçirilmemiş olarak VGGNet-16 düz modelinde bir sınıflandırma yapılmıştır. Bunun sonucunda %63'lük bir doğruluk oranı sağlanmıştır.


Daha sonra aynı veri setinin öğrenme aktarımlı VGGNet-16 modeliyle sınıflandırma yapılmıştır. Bu sınıflandırma sonucunda ise %78,43'lük bir doğruluk oranına ulaşılmıştır. Düz modele göre öğrenme aktarımlı modelin eğitilmesi ile daha iyi bir sonuç alındığı görülmüştür. Dönem sayılarına göre en iyi 7. dönemde bu sonuca ulaşılmıştır. Bu sınıflandırmada model başarısı sonuçları Çizelge 4.2'de verilmiştir.

Sınıfların bireysel doğruluk oranlarına bakıldığında yüksek bir oran görünürken F1-skor değerlerinde düşük sonuçlar bulunmaktadır. F1-skorlarına göre firkateyn, çıkarma gemisi ve karakol gemisi en düşük F1-skoruna sahip sınıflar olarak görülmektedir. Veri setindeki gemi görüntülerine bağlı olarak ve bu gemi tiplerinin diğer tipler ile benzerliklerinden kaynaklı bu sonuçlar alınmıştır. Gemi veri setinde bulunan önden ve arkadan çekilmiş gemi resimlerine göre bu açılardan sınıflar arası benzerlikler olduğu görülmüştür.

Çizelge 4.2. Tam veri seti için öğrenme aktarımlı modelin sınıflandırma sonuçları

Sınıf	Doğruluk Oranı (%)	Kesinlik	Duyarlılık	F1-Skor
Uçak Gemisi	94,15	0,95	0,81	0,88
Muhrip	86,49	0,82	0,76	0,79
Fırkateyn	90,73	0,38	0,74	0,50
Çıkarma Gemisi	94,96	0,72	0,55	0,63
Mayın Harbi	96,57	0,66	0,94	0,77
Karakol Gemisi	93,95	0,72	0,69	0,71
Denizaltı	100	1,0	1,0	1,0

Bu sonuçlar sınıflar arası benzer ana gemi tiplerinin sivil gemilere nazaran [5] askeri gemilerde daha çok olduğunu ortaya çıkarmıştır. Bu tam veri seti için karmaşıklık matrisi Şekil 4.1’de gösterilmiştir.



Şekil 4.1. Tam veri seti için karmaşıklık matrisi

Askeri gemi tipleri her ne kadar ana tiplere bağımlı olsa da alt görev tipleri aynı ana tip ile modernize edilebilmektedir. Veri setinin alındığı kaynaklarda bu alt tipler bulunmadığı için ana tiplerde ayırım yapılmamıştır. Bu yüzden muhrip, fırkateyn, çıkarma gemisi ve karakol gemilerinde benzer özelliklerin olduğu görülmüştür.


Sınıflandırma çalışmalarında veri setinin sınıflar arasındaki sayısal bir homojen dağılımı ve verilerin kalitesinin aynı olması başarı oranını artırmaktadır. Buna uygun olarak bölüm 3.2.3’te anlatılan veri setinin ön işlemden geçirilmesiyle bir alt veri seti hazırlanmıştır.

Böylece yandan aynı yöne bakan gemilerin olduğu bir alt veri seti oluşturulmuştur. Bu alt veri seti ile tekrardan sınıflandırma yapılmıştır. Bu durumda doğrulama oranı %91,02'ye yükselmiştir. Dönem sayılarına göre en iyi 6. dönemde bu sonuca ulaşılmıştır. Çizelge 4.3'te model başarı sonuçları verilmiştir.

Çizelge 4.3. Alt veri seti için öğrenme aktarımlı modelin sınıflandırma sonuçları

Sınıf	Doğruluk Oranı (%)	Kesinlik	Duyarlılık	F1-Skor
Uçak Gemisi	96,95	0,94	0,94	0,94
Muhrip	94,41	0,94	0,88	0,91
Fırkateyn	97,29	0,79	0,83	0,81
Çıkarma Gemisi	97,63	0,89	0,86	0,88
Mayın Harbi	98,64	0,88	0,96	0,92
Karakol Gemisi	97,46	0,82	0,91	0,87
Denizaltı	99,66	0,97	1,0	0,98

Şekil 4.2'de alt veri seti için yapılan sınıflandırma çalışmasının karmaşıklık matris sonucu bulunmaktadır.




Şekil 4.2. Alt veri seti için karmaşıklık matrisi

Ön işleminden geçirilen veri seti ile tam veri setinin sınıflar arası F1-skor karşılaştırmaları Çizelge 4.4'te yer almaktadır. Bu çizelgeden de görüldüğü üzere sınıflar bazında F1-skor değişimlerinde en çok artış oranının Fırkateyn, Çıkarma Gemisi, Mayın Harbi sınıflarında olduğu görülmektedir.

Çizelge 4.4. Alt ve tam veri seti için sınıfların F1-skor sonuçları

Sınıf	F1-skor (Tam veri seti)	F1-skor (Alt veri seti)
Uçak Gemisi	0,88	0,94
Muhrip	0,79	0,91
Fırkateyn	0,50	0,81
Çıkarma Gemisi	0,63	0,88
Mayın Harbi	0,77	0,92
Karakol Gemisi	0,71	0,87
Denizaltı	1,0	0,98

Şekil 4.3'de dönem sayılarına göre doğruluk oranlarının grafiği gösterilmiştir. En iyi doğruluk oranı 6. dönem sayısı için bulunmuştur.



Şekil 4.3. Alt veri seti için doğruluk oranı - dönem sayısı grafiği

Yapılan bu üç deneyin ve modellerin sınıflandırma sonuç bilgileri Çizelge 4.5'te gösterilmiştir.

Çizelge 4.5. Sınıflandırma sonuçları

Veri Seti	Model	Doğruluk Oranı (%)	F1-Skor
Tam	VGG-16 (Düz)	63,23	0.66
Tam	VGG-16 (Öğrenme Aktarımı)	78,43	0.75
Alt – Önişlemeden geçirilmiş	VGG-16 (Öğrenme Aktarımı)	91,02	0,91

Bu çalışmadaki sınıflandırma sonuçlarının önceki çalışmalarla karşılaştırılması Çizelge 4.6'da gösterilmiştir. Alt veri seti ile eğitilen ve öğrenme aktarımı kullanılan VGGNet-16'nın sınıflandırma doğruluk oranının hem bu çalışmadaki tam veri ile yapılan düz ve öğrenme aktarımlı VGGNet-16 modellerinden hem de diğer çalışmalardaki AlexNet ve VGGNet-16 modelleri ile yapılan sınıflandırmaların doğruluk oranlarından daha yüksek olduğu görülmüştür.

Çizelge 4.6. Sınıflandırma karşılaştırmaları

Model	Doğruluk Oranı (%)	Veri Seti
AlexNet [10]	73,14	Sivil
AlexNet [30]	88,22	Sivil, Askeri
VGGNet-16 (Öğrenme Aktarımı)	78,43	Askeri (7 sınıflı tam veri seti)
VGGNet-16 (Öğrenme Aktarımı)	91,02	Askeri (7 sınıflı alt veri seti)

Bu başarı sonuçlarına göre sivil ve askeri olmak üzere iki sınıflı uygulamanın ilk sınıflandırma çalışması için de öğrenme aktarımlı model kullanılmıştır. Bu sınıflandırma sonucunda da %97,14'lük bir doğruluk oranı elde edilmiştir.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında açık kaynaklardan yeni bir veri seti oluşturulmuştur. Bu veri seti gelecekte yapılacak sınıflandırma ve diğer yapay zeka uygulamalarında kullanılabilecektir.

Daha sonra günümüzün başarılı ESA modeli VGGNet-16 ile sınıflandırma yapılmış ve sonuçlar literatürdeki önceki çalışmalarla karşılaştırılmıştır. Çalışmada en iyi sonuç ön işlemden geçirilmiş alt veri seti üzerinde öğrenme aktarımı uygulanmasıyla alınmıştır. Kısıtlı kaynaklardan dolayı az sayıda veri üzerinde öğrenme aktarımının kullanılması çalışmanın başarısını artırdığı gözlenmiştir.

Veri seti içeriğine bağlı olarak farklı veri setlerinde verileri ön işlemden geçirmeye ihtiyaç duyulmayabilir. Ancak bu çalışmadaki veri setinde hem kaynak görüntülerin geminin yönünden bağımsız olması hem de askeri tipteki gemilerin ana tiplere bağlı olmadan kendi içinde farklılıklar içermesi ön işlem uygulamayı mecbur kılmıştır.

Çalışmanın sonuçları, modelin doğruluk oranının görüntülerin çekim açısından ve gemilerin açılarından etkilendiğini ortaya çıkarmaktadır. Bu nedenle, geminin iskele ve sancak tarafından çekilen görüntüleri eğitim doğruluğunu artırmaktadır. Sonraki çalışmalarda, veri setinin iyileştirilerek hedeflenen sistemlerin kaynaklarından alınan görüntüler ile yeniden bir sınıflandırma çalışması yapılması planlanmaktadır. Bununla birlikte yapılan sınıflandırma çalışmasının video analizi araçlarına entegre edilerek, askeri gemilerin gerçek zamanlı olarak tanınmasının sağlanması amaçlanmaktadır. Ayrıca farklı derin öğrenme modellerinin uygulanarak sonuçların iyileştirilmesi de düşünülmektedir.

KAYNAKLAR


1. Kara A. (2013). *Arama Kurtarma Operasyonlarında Risk Analizi ve Türkiye için Arama Kurtarma Model Araştırması*. T.C. Ulaştırma, Denizcilik ve Haberleşme Bakanlığı.
2. Premaratne P., Safaei F. (2009). *Ship Classification by Superstructure Moment Invariants*. In: Proceedings of the International Conference on Intelligent Computing, 327-335.
3. Chang, Y., Anagaw, A., Chang, L., Wang, Y. C., Hsiao, C., Lee, W. (2019). Ship Detection Based on YOLOv2 for SAR Imagery. *Remote Sensing* 11(7), 786.
4. Liu, Y., Cui, H.Y., Kuang, Z., Li, G.Q. (2017). *Ship Detection and Classification on Optical Remote Sensing Images Using Deep Learning*. ITM Web of Conferences 2017. 12.
5. Dao-Duc, C., Xiaohui, H., Mor`ere, O. (2015). *Maritime vessel images classification using deep convolutional neural networks*. In: Proceedings of the Sixth International Symposium on Information and Communication Technology, SoICT, 276–281. ACM, New York.
6. Zhang, M.M., Choi, J., Daniilidis, K., Wolf, M. T., Kanan, C. (2015). *VAIS: A Dataset for Recognizing Maritime Imagery in the Visible and Infrared Spectrums*. Computer Vision and Pattern Recognition Workshops (CVPRW).
7. Yüksel, G.K., Yalıtuna, B., Tartar, Ö.F., Adlı, F.C., Eker, K., Yörük, O. (2016). *Ship recognition and classification using silhouettes extracted from optical images*. 24th Signal Processing and Communication Application Conference (SIU), 1617-1620.
8. Milicevic M., Zubrinic K., Obradovic I., Sjekavica T. (2018). Data Augmentation and Transfer Learning for Limited Dataset Ship Classification. *WSEAS Transactions on Systems and Control*, 13, 460-465.
9. Leclerc, M., Tharmarasa, R., Florea, M., Boury-Brisset, A., Kirubarajan, Thia., Duclos-Hindie, N. (2018). *Ship Classification Using Deep Learning Techniques for Maritime Target Tracking*. 21st International Conference on Information Fusion (FUSION), 737-744.
10. Gundogdu, E., Solmaz, B., Yücesoy, V., Koç, A. (2017). MARVEL: A Large-Scale Image Dataset for Maritime Vessels. In: *Computer Vision – ACCV 2016, Lecture Notes in Computer Science*, 165-180.
11. Tammina, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications (IJSRP)*, 9420.
12. Relekar, H., Shanmugam P. (2021). *Transfer Learning Based Ship Classification in Sentinel-1 Images Incorporating Scale Variant Features*. Advances in Space Research Volume 68, Issue 11, 2021, 4594-4615.

13. Huang, Z., Sui, B., Wen, J., Jiang, G. (2020). An Intelligent Ship Image/Video Detection and Classification Method with Improved Regressive Deep Convolutional Neural Network. *Complexity*, 2020(1):1-11.
14. Şeker, A., Diri, B., Balık H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
15. İnternet: Stanford's Deep Learning – CS 230 Course Site. URL: <https://stanford.edu/~shervine/teaching/cs-230/>, Son Erişim Tarihi: 10.11.2021.
16. İnternet: VGG - Keras IO, URL: <https://keras.io/api/applications/vgg/>, Son Erişim Tarihi: 12.03.2022.
17. Krizhevsky, A., Sutskever, I., Hinton G. H. (2012). *ImageNet Classification with Deep Convolutional Neural Networks*. In Advances in Neural Information Processing Systems 25, 1097-1195.
18. Simonyan, K., Zisserman A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. The 3rd International Conference on Learning Representations (ICLR2015), arXiv 1409.1556.
19. İnternet: ImageNet Large Scale Visual Recognition Challenge (ILSVRC). URL: <https://www.image-net.org/challenges/LSVRC/>, Son Erişim Tarihi: 23.11.2021.
20. Deng, J., Dong, W., Socher, R., Li, L.-J., Li K., Fei-Fei L. (2009). *Imagenet: A large-scale hierarchical image database*. In 2009 IEEE conference on computer vision and pattern recognition, 248-255.
21. İnternet: Transfer learning and fine-tuning, TensorFlow Core. URL: https://www.tensorflow.org/tutorials/images/transfer_learning, Son Erişim Tarihi: 05.03.2022.
22. Torrey, L., Shavlik, J. (2010). *Transfer learning*. Handbook of research on machine learning applications and trends: algorithms, methods, and techniques, IGI Global, 242-264.
23. Yosinski, J., Clune, J., Bengio, Y., Lipson H. (2014). *How transferable are features in deep neural networks?*. Advances in Neural Information Processing Systems 27, 3320-3328.
24. İnternet: Transfer learning and fine-tuning, TensorFlow Core. URL: https://www.tensorflow.org/tutorials/images/transfer_learning, Son Erişim Tarihi: 05.03.2022.
25. İnternet: Caffe to TensorFlow, GitHub. URL: <https://github.com/ethereon/caffe-tensorflow>, Son Erişim Tarihi: 03.04.2022.
26. İnternet: Ship Shapes, Anatomy and Types of Naval Vessels, Naval History and Heritage Command. URL: <https://www.history.navy.mil/research/library/online-reading-room/title-list-alphabetically/s/ship-shapes-anatomy-and-types-of-naval-vessels.html>, Son Erişim Tarihi: 06.02.2022.

27. İnternet: Shipspotting Ship Tracker. URL: <http://www.shipspotting.com/gallery/categories.php>, Son Erişim Tarihi: 13.08.2021.
28. İnternet: List of naval ship classes in service, Wikipedia. URL: https://en.wikipedia.org/wiki/List_of_naval_ship_classes_in_service, Son Erişim Tarihi: 22.08.2021.
29. Abadi, M. et al.: *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*, <http://www.tensorflow.org> (2015)
30. Atalar O., Bartan B. (2017). *Ship Classification Using an Image Dataset*. Corpus ID: 29004678

EKLER

EK-1. Sınıflandırmada kullanılan VGGNet-16 ağının ayrıntılı ağ görüntüsü



Şekil 1.1. VGGNet-16 ağı



GAZİ GELECEKTİR..