



Gemi Çeşitlerinin Derin Öğrenme Tabanlı Sınıflandırılmasında Farklı Ölçeklerdeki Görüntülerin Kullanımı

Emirhan Kıran¹, Bahadır Karasulu², Emin Borandag^{3*}

¹ Havelsan, Yazılım Geliştirme Bölümü, İstanbul, Türkiye

² Çanakkale Onsekiz Mart Üniversitesi, Bilgisayar Mühendisliği Bölümü, Çanakkale, Türkiye

³ Manisa Celal Bayar Üniversitesi, Yazılım Mühendisliği Bölümü, Manisa, Türkiye

ekiran@havelsan.com.tr, bahadirkarasulu@comu.edu.tr, emin.borandag@cbu.edu.tr

Öz

Günümüzde lojistik ve deniz ulaşımına dayanan ticaret oldukça önem kazanmıştır. Buna dair oluşan trafik göz önüne alındığında gemi çeşitlerinin sınıflandırılarak ayrıştırılması, taşıma, depolama maliyetleri açısından ve güvenlik konusunda önem arz etmektedir. Deniz üzerinde farklı görevleri icra etmekte olan gemilerin sınıflandırılması bu çalışmada ele alınarak, derin öğrenme yöntemleri sayesinde yüksek doğrulukta bir gemi sınıflandırma yapılabilmesi için gemi görüntüleri veri kümesi oluşturulmuştur. Veri kümesinden elde edilen içeriği ifade ederken özneliliklerin daha yüksek seviyeden anlamsal olarak zengin olmasından dolayı, klasik makine öğrenmesi yöntemine kıyasla derin öğrenme çalışmamızda tercih edilmiştir. Derin öğrenme modellerinin eğitiminde ve test edilmesinde kullanılmak üzere bu veri kümesi açık kaynaklı İnternet sitelerinden ağ kazıma (web scraping) yöntemi sayesinde çeşitli gemi görüntülerinin edinimi ile oluşturulmuştur. YOLOv5 ve Xception derin öğrenme modelleri eğitilerek en uygun sınıflandırma başarımları elde edilmiştir. Deneyler sonucunda her iki model ile yaklaşık olarak %96 ilâ %99 arası doğruluk oranında başarımları elde edilmiştir. Varılan bilimsel bulgulara ve tartışmaya çalışmamızda yer verilmektedir.

Anahtar kelimeler: Derin Öğrenme, Gemi Sınıflandırma, Görüntü İşleme.

Deep Learning based Ship Variants Classification Using Different Scale Images

Abstract

Nowadays, trade based on logistics and sea transportation has gained importance. Considering the traffic related to this, the classification and discrimination of ship types are important in terms of transportation and storage costs, and safety. The classification of ships performing different tasks on the sea is handled in this study, and a ship image dataset has been created in order to make a high accuracy ship classification thanks to deep learning methods. It is preferred in our deep learning study in comparison to the classical machine learning method, as the features are semantically richer as the higher level, while expressing content from the dataset. It was created by the acquisition of various ship images thanks to the web scraping method. YOLOv5 and Xception deep learning models were trained to obtain the most appropriate classification performance. As a result of the experiments, an accuracy rate of approximately between 96% and 99% was achieved with both models. Scientific findings and discussion are included in our study as well.

Keywords: Deep Learning, Ship Classification, Image Processing.

* Sorumlu yazar.
E-posta adresi: emin.borandag@cbu.edu.tr

Alındı : 19 Mayıs 2022
Revizyon : 1 Ağustos 2022
Kabul : 17 Ağustos 2022

1. Giriş (Introduction)

Sayısal görüntüler kullanılarak yapılan gemi sınıflandırılması, denizlerdeki trafiğin yönetilmesi ve izlenmesi, güvenlik kontrol uygulamaları gibi birçok alanda kullanılmaktadır. Gemi sınıflandırma problemleri için zor olan nokta; çok çeşitli gemilerin olması ve bazı gemilerin birbirine çok benzemesidir. Bunların yanı sıra, iyi bir veri kümesi elde edebilmek de ayrı bir problemdir. Gemi tanıma ve sınıflandırma amacıyla şablon eşleştirme uygulamalarında anahtar noktaların elde edilmesi için betimleyici özniteliklerin oluşturulmasında Ölçekle Değişmez Öznitelik Dönüşümü (Scale-Invariant Feature Transform, SIFT) yöntemi (Lowe, 2004) elde ettiği öznitelik ve eşleştirmeler bakımından yüksek bir başarımlı sonucu vermemektedir.

Dolapçı ve Özcan'ın 2021 yılındaki çalışmasında; gemi görüntülerinin bloklarının da melez öznitelik vektörleri ile temsil edilmesi gerçekleştirilerek, Apache Spark'daki makine öğrenmesi yöntemleri ile kullanılarak görüntülerin sınıflandırılması sağlanmıştır. Naif Bayes, Karar Ağaçları ve Rastgele Orman yöntemleri kullanılarak sınıflandırma gerçekleştirilmiş, kümeleme mimarisi ile çok daha hızlı bir sınıflandırma sonucunda geliştirdikleri melez yöntem ile %99,62 oranı elde etmişlerdir (Dolapçı ve Özcan, 2021).

Derin öğrenme için oluşturulan modeller, katmanlı yapıları sayesinde veriden elde edilen özniteliklerin temsili öğrenme (representation learning) yoluyla alt seviye özniteliklerden yola çıkarak daha üst seviyede özniteliklerin içerildiği haliyle anlamlı bilginin elde edilmesini otomatik bir biçimde sağlamayı hedeflemektedir. Derin öğrenme alanında temel taşlarından biri olarak evrişimli sinir ağları (convolutional neural networks, CNN) (LeCun vd., 1989) sınıflandırma problemlerinde sağlamış olduğu öznitelik soyutlaması tabanlı temsili öğrenme nedeniyle yüksek başarımlı elde edilmesini sağlamaktadır. Evrişimli sinir ağları (ESA) öznitelik elde edilmesini otomatikleştiren güçlü yeteneklere sahip olan bir yapıdır. Çalışmamızdaki gemi sınıflandırma ve tanıma için ESA tabanlı sinir ağı modelleri olan iki model kullanılmaktadır. Bu yapılar, çalışmadaki on üç farklı sınıfa ait gemilerin sınıflandırılmasında güçlü birer sınıflandırıcı ve gemi tipi ayrıştırıcısı olarak kullanılmıştır.

Literatürdeki benzer bir çalışma olarak Zhenzhen ve arkadaşlarının gerçekleştirdiği (Zhenzhen vd., 2019) çalışma incelendiğinde elde edilen başarımlı değerleri ve sınıflandırılmak istenen gemi çeşitlerinin sayısının yetersiz olduğu görülmüştür. Bu nedenle ilgili çalışmadan farklı olarak yeni bir veri kümesi oluşturulmuş, YOLOv5 (Jiang vd., 2022) derin öğrenme mimari modeli ve ön eğitilmiş Xception (Chollet, 2016) derin öğrenme mimari modeli öğrenme transferi (transfer learning) yoluyla eğitilerek sonuçları en uygun sınıflandırma sonuç kararının verilebilmesi için kullanılmıştır. Deneylerdeki gerçekleştirilen eğitim

sonucunda derin öğrenme mimari modelleri olarak YOLOv5 ve Xception modelleriyle yaklaşık %96 ilâ %99 arasında doğruluk oranı olarak başarımlı elde edilmiştir. Çalışmamız beş bölümden oluşmaktadır. İkinci bölümde, çalışma kapsamında oluşturularak deneylerde kullanılan gemi görüntüleri veri kümesinin detayları verilmektedir. Üçüncü bölümde çalışmadaki materyal ve yöntemlerin hakkında bilgiler verilerek, deneylerde kullanılan derin öğrenme modellerinin teknik detaylarına yer verilmektedir. Dördüncü bölümde deneylerden elde edilen nicel sonuçlar, bu sonuçlara dair yorumlamalar ve derin sinir ağı mimari modellerinin kıyaslamaları verilmektedir. Beşinci bölümde sonuçlar üzerinden varılan bilimsel bulgular değerlendirilerek yapılan tartışmaya yer verilmiştir.

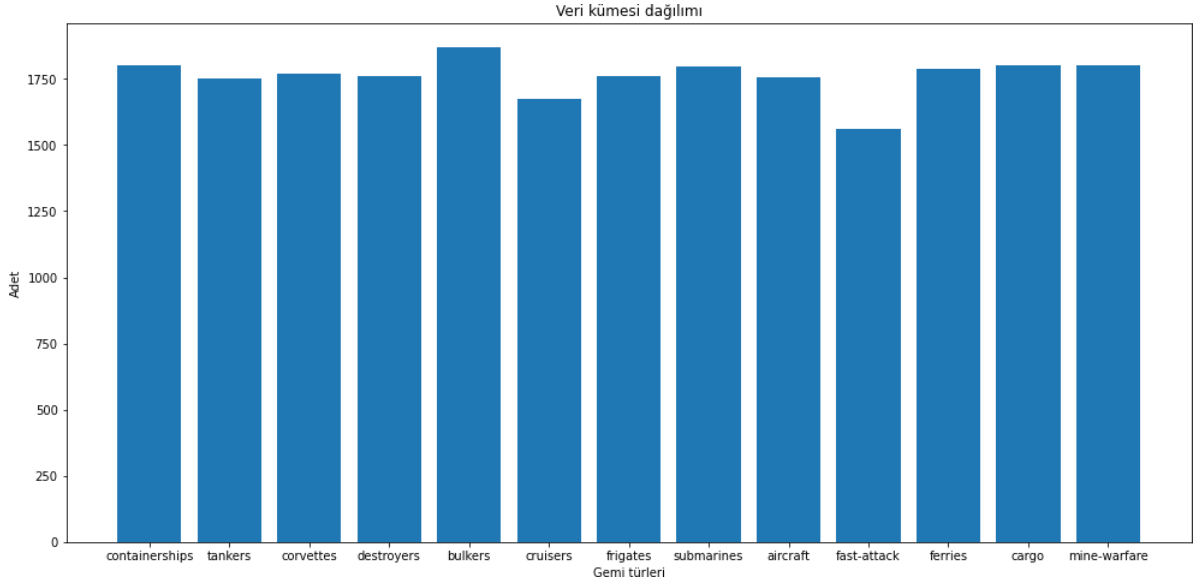
2. Veri Kümesi (Dataset)

Teknolojinin de gelişmesiyle birlikte denizcilik ve gemi üretiminde de gelişmeler hızla devam etmektedir. Hızla gelişen denizcilik faaliyetleri, farklı görevler için farklı gemilerin üretilmesini gerektirmektedir. Genel olarak bakıldığında sivil ve askeri olmak üzere iki farklı gemi çeşidi bulunmaktadır. Daha detaylı incelendiğinde sivil gemiler; yolcu gemisi, yük gemisi, konteyner gemisi ve kargo gemisi tipi bulunduğu görülmektedir. Bunların haricinde askeri gemiler ise; firkateyn, destroyer, uçak gemisi, deniz altı olmak üzere alt türlere ayrılmaktadır. Çalışmamızda sekiz farklı savaş gemisi ve beş farklı sivil gemi olmak üzere toplamda on üç farklı tipte gemi sınıflandırılması gerçekleştirilmiştir.

Derin öğrenme modelleri ön eğitimsiz olduğunda eğitimin sağlıklı olarak başarımlı artırmak için oldukça fazla veriye ihtiyaç duyulmaktadır. İnternet sitelerinde bulunan çeşitli çeşitli halka açık görüntü veri kümeleri göz önüne alındığında veri sayısının az, veri kalitesinin yetersiz ve dengeli olmayan veri dağılımına sahip veri kümelerinin bulunduğu görülmektedir. Bu sorunu çözmek adına Python programlama dili için geliştirilen HTTP/1.1 altyapısını kullanarak doğrudan sorgu cümleleri belirtmeye ve POST verisini kodlamaya gerek kalmadan kullanımı sağlayan "requests" (Reitz, 2022) ve HTML/XML dosyalarından veri çekmeye yarayan ve ayrıştırma ağaç yapısını düzenleme, arama ve yönetmede kullanılan "BeautifulSoup" (Richardson, 2021) kütüphaneleri sayesinde iStock (Livingstone, 2000), Unsplash (Cho, 2013), Pexels (Obrecht, 2014), GettyImages (Getty, 2007) Vessel Finder ve Marine Traffic (Lekkas, 2007) İnternet sitelerinden ağ kazıma (web scraping) yöntemi ile 13 farklı sınıf için 22.900 adet görüntü kullanılmıştır. Bu görüntülerden 20.300 âdeti eğitim geri kalan 2.600 adet ise test verisi için kullanılmıştır. Bu verilerin YOLOv5 modeli eğitimlerinde kullanılabilir hale gelebilmesi adına "LabelImg" (Rosenfeld vd., 2015) isimli bir programla nesnelere içeren referans bilgi halinde etiketlenmesi (annotation) gerekmektedir. Veri kümesindeki tüm görüntüler

içerdikleri nesnelere göre bu yöntem ile etiketlenmiştir. Şekil 1'de veri kümesindeki verilerin sınıflara göre

dağılımı görülmektedir.



Şekil 1 Veri kümesi sınıfların dağılım grafiği (Bar chart plot for ship variant dataset classes)

3. Materyal ve Yöntemler (Material and Methods)

Sayısal görüntüler ile gemi sınıflandırma ve tanıma probleminin çözülebilmesi için ilk olarak veri kümesi üzerinde etiketleme ve ön işleme adımları tamamlanmıştır. Ön işleme aşamasında, ağ kazıma (web scraping) ile elde edilen 30.416 adet veri incelenmiştir. Elde edilen bazı görüntülerin boyut ve çözünürlük değerleri uygun olmadığı görülmüş ayrıca elde edilen veri kümesi üzerinde incelemeler yapılarak gemi içi, sahil ve mürettebat gibi geminin algılanmasını zorlaştıranlar tespit edilerek veri kümesinden silinmiştir. Bu ön işleme aşaması sonucunda 22.900 adet görüntü içeren bir veri kümesi elde edilmiştir. Bu sayede verilerin deneylerde kullanılan sinir ağı modellerinin girdi biçimine uygun hale gelmesi sağlanmıştır. Sonraki aşamadaysa ESA tabanlı YOLOv5 ve Xception modelleri için eğitim gerçekleştirilmiştir. Bu bölümde deneylerde kullanılan bu modellerin teknik detaylarından bahsedilmektedir.

3.1. Evrişimli Sinir Ağı Tabanlı Modeller (Models Based on Convolutional Neural Network)

Çalışmamızdaki deneylerde kullanılmak üzere Xception ve YOLOv5 modelleri programatik yoldan oluşturularak, girdi verisi çalışmamızdaki veri kümesindeki görüntüler olacak şekilde bu modellere verilmiştir. Literatürdeki kullanım amacıyla Xception modeli, "ImageNet" isimli 1.000 sınıflı büyük bir veri kümesiyle eğitildiğinden dolayı ön eğitimli olarak

kullanılarak öznitelik elde etme, eğitim transferi (transfer learning) ve ince ayarlama (fine tuning) açısından deneylerimizdeki sınıflandırma görevlerinin başarımını artırmaktadır. ImageNet, temel aldığı hiyerarşinin her bir düğümünün yüzlerce ve binlerce görüntüyle gösterildiği WordNet hiyerarşisine göre düzenlenmiş bir görüntü veritabanıdır. YOLOv5 modeli danışmanlı eğitim (supervised learning) tabanlı çalıştığı için etiketli veriye ihtiyaç duymakta, eğer etiketli veri sınıfları yeterince iyi tanımlanmışsa başarımı artmaktadır. Eğitim ortamının oluşturulmasında Tensorflow v2.0 (Abadi vd., 2016), Keras v2.8.0 (Chollet, 2016), Numpy (Harris vd., 2020), Pandas (Daniel, 2018) PyTorch 1.10.0 (Lorica, 2017) kütüphaneleri kullanılarak veri işleme aşamaları gerçekleştirilmiştir.

Çalışmamızda eğitimi gerçekleştirilen ilk model Xception tabanlıdır. Bu model görüntülerden öznitelik elde etmek için evrişim katmanları, boyut indirgemek amacıyla azami biriktirme (max pooling) katmanını ve tüm bu özellikleri birleştirmek için ise tam bağlı (fully connected) katmanları kullanmaktadır. Bunların dışında normalizasyon ve düzenleme işlemleri için de çeşitli katmanlar tercih edilmiştir. Bunlara ek olarak her evrişimli ve tam bağlı katmanlarda doğrusal olmayan olan düzenlenmiş doğrusal birim (Rectified Linear Unit, ReLU) aktivasyon fonksiyonu seçilmiştir. Geliştirilen bu model Xception tabanlıdır fakat bazı kısımları değiştirilmiştir. Çalışmaya özgü sınıflandırma işlemi için temel alınan modelin tam bağlı katmanları devre dışı bırakılmıştır. Bunun yerine iki boyutlu genel ortalama biriktirme

(GlobalAveragePooling2D) katmanı ve Yoğun (Dense) katmanları modelin sonuna eklenerek Xception tarafından elde edilen öznetelik haritası indirgenerek algılayıcı ağı biçimindeki tam bağlı katmana sınıflandırılmak üzere geçirilmiştir, bu yolla gemi sınıflandırma problemi için uygun bir model elde edilmiştir.

Çalışma kapsamında eğitimi gerçekleştirilen ikinci model YOLOv5 tabanlıdır. YOLO (You Only Look Once) görüntüleri bir ızgara sistemine bölen nesne algılama tabanlı bir yapıdır (Jiang vd., 2022). Izzaradaki her hücre, kendi içindeki nesnelere algılamaktan sorumludur. YOLO, hafif sıklet bir model büyüklüğüne sahip olduğundan ve veri iyileştirme sağladığı için hızı ve doğruluğu oldukça yüksek, en ünlü nesne algılama modellerinden biri olarak kabul edilmekte (Jiang vd., 2022), Xception'dan farklı olarak sınıflandırılan nesnelere konumlarını da belirlemektedir. YOLOv5 modelinin mimarisini yakından bakılacak olursa görsel verilerden öznetelik elde etmek için evrişim katmanlarını, boyut indirgemek için de azami biriktirme katmanı kullanılmakta, fakat Xception'dan farklı bir yapıda tasarlanmıştır (Chollet, 2016).

Çalışmamızdaki YOLOv5 modelinin farklı alt modelleri mevcuttur. Bunlar belirlenmek istenilen nesnelere boyutlarına bağlı olarak tercih edilmektedir. Tespit edilen nesne olarak gemi haricinde kalan diğer nesnelere arka plan nesnelere olarak sınıflandırılmıştır. Gemi tanıma ve sınıflandırma problemine uygun olarak rota ölçekli ve büyük ölçekli modeller ile eğitim işlemleri gerçekleştirilmiştir. Başarım ve sınıflandırma ölçütlerine bakıldığında büyük ölçekli modelin daha başarılı olduğu görülmektedir. Gerçekleştirilen çalışma kapsamında büyük ölçekli modelin kullanılması uygun görülmüştür. Buna istinaden elde edilen deney sonuçlarında 13 adet gemi sınıfının yanı sıra arka plan sınıfına ait değerlerde elde edilmiştir.

4. Deneysel Sonuçlar (Experimental Results)

Deneylerde kullanılan görüntüler, eğitim ve test aşamalarında kullanılmak üzere ayrılmıştır. Deneylerde, 20.300 adet görüntü verisi ile eğitilen derin öğrenme modellerini test etmek için veri kümesinde ayırmış olduğumuz her bir sınıf için 200 adet görüntüden oluşan toplam 13 sınıf için 2.600 adet veri ile test işlemleri gerçekleştirilmiştir. Bu test işlemleri sonucunda elde edilen ortalama doğruluk oranı YOLOv5 için %96,6 iken Xception modeli için %99,44 olarak bulunmuştur. Test sonuçlarını derinlemesine incelediğimizde; bazı savaş gemilerinin birbirlerine benzerliğinden dolayı başarı oranı kategori bazında ortalamanın altında kalmıştır. Girdi görüntüleri farklı Internet sitelerinden edinildiği için farklı ölçeklerde ve çözünürlüklerde olmaktadır. Bunlar özellikle YOLOv5 ve Xception modelleri için uygun ölçek ve çözünürlüklere indirgenerek girdi görüntüleri kümesine eklenmişlerdir. YOLOv5 için deneylerde

kullanılan renkli üç kanal (Kırmızı-Yeşil-Mavi, RGB) girdi görüntüsü çözünürlüğü 640x640 iken, Xception için 299x299 çözünürlüktedir.

Çalışmamızda bilgi elde etme kuramındaki nesnelere ölçütler olarak, duyarlık (precision) ve anma (recall) ölçütleri deneydeki modellerin başarılarının ölçülmesinde ve değerlendirilmesinde kullanılmıştır. Bu ölçütlere batığımızda; her gemi sınıfı için hesaplanarak sonuçlar incelenmiştir. Bu ölçütlerde sıklıkla kullanılan belirli nesnelere ölçümler göz önüne alınır. Buna göre doğru pozitif (true positive, TP), doğru negatif (true negative, TN), yanlış pozitif (false positive, FP) ve yanlış negatif (false negative, FN) ölçümleri belirli kıyaslama yapılacak ölçütlerin hesaplanmasında da kullanılmaktadır. Duyarlık ölçütü pozitif olarak tahminlenen değerlerin kaç tanesinin gerçekten de pozitif değerli olduğunu ifade etmektedir ve Eşitlik (1) ile verilmektedir (Karasulu, 2018).

$$Duyarlık = \frac{TP}{(TP+FP)} \quad (1)$$

Anma ölçütü ise ilgili modelin pozitif olarak tahmin etmesi gerekirken ne kadar değeri pozitif tahmin ettiğini gösterir ve Eşitlik (2) ile verilmektedir (Karasulu, 2018).

$$Anma = \frac{TP}{(TP+FN)} \quad (2)$$

Doğruluk oranı ölçütü, bir modelin başarımını ölçmede kullanılan en genel ölçüttür, fakat tek başına yeterli kanı oluşmasına yardımcı olamayabilir. Bu nedenle diğer ölçütleri de göz önüne almak gerekir. Doğruluk oranı ölçütü, Eşitlik (3) ile ifade edilmektedir (Karasulu, 2018).

$$Doğruluk = \frac{(TP+TN)}{(TP+FP+TN+FN)} \quad (3)$$

F1-skoru ise duyarlık ve anma'nın harmonik ortalaması olarak ifade edilir. Yukarıda bahsi geçen ölçütler ondalık sayı olarak veya yüz ile genişletilerek yüzdelik oran olarak da literatürdeki çalışmalarda kullanılabilir. Bu bölümde her iki modelin bağımsız deneysel sonuçlarına nesnel ölçüt değerleri üzerinden yer verilmektedir.

YOLOv5 modelinin eğitim işlemlerinden sonra yapılan test işlemlerinde yüksek bir doğruluk oranında başarıya sahip olduğu gözlemlenmektedir. Buna göre; test işleminde 50 eğitim yineleme (epoch) sonucunda ortalama olarak %96,6 doğruluk oranı, %93,6 duyarlık, %93,6 anma değerleri elde edilmiştir. Sınıflandırma problemi için yapılan eğitim esnasında 0,0092 kayıp değerine kadar inen bir iyileştirme söz konusudur. Tablo 1'de YOLOv5 için deneyler sonucunda elde edilen gemi türlerine ait nesnel ölçüt değerleri yüzdelik oran olarak gösterilmiştir. Özellikle bu tabloda Xception modeli ile YOLOv5 modelinin daha kolay karşılaştırılabilmesi için deneylerimizde kullanılan 13 gemi sınıfı üzerinden bir gösterim yapılmıştır. Tabloda

görüldüğü üzere en yüksek doğruluk oranına sahip olan “Aircraft” gemi çeşidi olmuştur. Bunun başlıca sebebi görüntü içerisinde oransal olarak daha fazla miktarda

özneliğin bu gemi çeşitleri için tespit edilmiş olmasıdır.

Tablo 1. YOLOv5 ile bulunan gemi çeşitleri için nesnel ölçüt değerleri (Objective metric values for ship variant detected by YOLOv5)

Gemi Çeşitleri	Duyarlık	Anma	Doğruluk oranı
Aircraft	%99,1	%97,0	%99,4
Destroyer	%88,9	%88,9	%94,7
Containership	%98,5	%97,9	%99
Bulker	%96,2	%90,4	%95
Cargo	%96,2	%97,5	%97,8
Corvette	%87,4	%87,3	%92,1
Frigate	%85,1	%87,7	%93
Submarine	%97,9	%94,1	%99,3
Cruiser	%88,6	%94,7	%93,8
Tanker	%93,8	%94,2	%97,6
Ferrie	%96,2	%97,2	%99,1
Mine-warfare	%94,1	%98,0	%99,2
Fast-attack	%93,0	%91,3	%95,6
Bütün Sınıflar için Başarım Ortalama Değerleri	%93,6	%93,6	%96,6

YOLOv5 modelinin deneyler sırasında ilgili gemi sınıflarını ayırıştırırken sınıf farklılıklarını ne kadar doğru bir biçimde ortaya koyarak sınıflandırma yaptığını yukarıda bahsi geçen *TP*, *FP*, *TN*, *FN* tipi ölçülere göre ilgili dağılımın nasıl olduğuna dair

normalize edilmiş çapraz tahmin matrisi (confusion matrix) olarak Şekil 2’de verilmektedir. Aynı veri kümesiyle eğitimi gerçekleştirilen Xception modelinin, YOLOv5 modeline göre sınıflandırma sonucu daha başarılı olmuştur.

		Gerçek Etiket													
		Aircraft	Bulker	Cargo	Containership	Corvette	Cruiser	Destroyer	Fast-attack	Ferrie	Frigate	Mine-warfare	Submarine	Tanker	Arka Plan
Tahminlenen Etiket	Aircraft	0,97	0	0	0	0	0,01	0	0	0	0	0	0	0	0,02
	Bulker	0	0,90	0,01	0,01	0	0	0	0	0	0	0	0	0,01	0,07
	Cargo	0	0,01	0,97	0	0	0	0	0	0	0	0	0	0	0,02
	Containership	0	0	0	0,97	0	0	0	0	0	0	0	0	0	0,02
	Corvette	0	0	0	0	0,84	0	0,01	0,04	0	0,05	0,01	0	0	0,03
	Cruiser	0	0,01	0	0	0,01	0,94	0,03	0	0	0,01	0	0	0	0,05
	Destroyer	0	0	0	0	0,02	0,03	0,88	0	0	0,05	0	0	0	0
	Fast-attack	0	0	0	0	0,03	0	0	0,90	0	0	0	0	0	0,02
	Ferrie	0	0	0	0	0	0	0	0	0,87	0	0	0	0	0,07
	Frigate	0	0	0	0	0,06	0,01	0,06	0	0	0,87	0	0	0	0,13
	Mine-warfare	0	0	0	0	0	0	0	0,02	0	0	0,98	0	0	0
	Submarine	0	0	0	0	0	0	0	0	0	0,01	0	0,97	0	0
	Tanker	0	0,01	0,02	0	0	0	0	0	0	0	0	0	0,95	0,02
	Arka Plan	0,03	0,07	0,00	0,02	0,04	0,01	0,02	0,04	0,13	0,01	0,01	0,03	0,04	0,02

Şekil 2 YOLOv5 modeline ait normalize edilmiş çapraz tahmin matrisi (Normalized confusion matrix for YOLOv5 model)

Eğitim esnasında yapılan 50 eğitim yineleme (epoch) adımı sonunda ortalama olarak Xception modeliyle %99,44 doğruluk oranında başarımlı değeri elde etmiştir. Normalize edilmiş çapraz tahmin matrisi incelendiğinde, bazı gemi türlerinin birbirlerine

benzemesinden dolayı başarımlı oranı düşük gözükmektedir. Xception modeline ait normalize edilmiş çapraz tahmin matrisi Şekil 3’te görülmektedir.

		Gerçek Etiket													
		Aircraft	Bulker	Cargo	Containership	Corvette	Cruiser	Destroyer	Fast-attack	Ferrie	Frigate	Mine-warfare	Submarine	Tanker	
Tahminlenen Etiket	Aircraft	0,98	0	0	0	0	0,01	0	0	0	0	0	0,005	0	
	Bulker	0,005	0,97	0	0	0	0	0	0	0	0	0,005	0	0,02	
	Cargo	0,005	0,01	1	0	0	0	0	0	0	0	0	0	0,01	
	Containership	0	0,01	0	1	0	0	0	0	0	0	0	0	0,005	
	Corvette	0	0	0	0	0,87	0,005	0	0,015	0	0,03	0	0,005	0	
	Cruiser	0	0	0	0	0,015	0,955	0,03	0,005	0	0,02	0	0	0	
	Destroyer	0	0,005	0	0	0,015	0,03	0,935	0,005	0	0,02	0,005	0	0	
	Fast-attack	0	0	0	0	0,035	0	0	0,96	0	0	0	0	0	
	Ferrie	0,005	0,005	0	0	0	0	0	0	1	0	0	0,005	0	
	Frigate	0,005	0	0	0	0,035	0	0,035	0	0	0,925	0	0	0	
	Mine-warfare	0	0	0	0	0,025	0	0	0,015	0	0,005	0,99	0	0,005	
	Submarine	0	0	0	0	0,005	0	0	0	0	0	0	0,985	0	
	Tanker	0	0	0	0	0	0	0	0	0	0	0	0	0,96	

Şekil 3 Xception modeline ait normalize edilmiş çapraz tahmin matrisi (Normalized confusion matrix for Xception model)

Yukarıdaki nesnel ölçütleri kullanılarak her bir gemi türü sınıfı için bu hesaplamaları gerçekleştirdiğimizde sonuçlar yüzdelik oran olarak aşağıda verilen Tablo 2' deki şekilde olmaktadır. Tabloda görüldüğü üzere en yüksek doğruluk oranına sahip olarak "Containership" ve "Ferrie" gemi çeşitleri olmuştur. Bunun başlıca sebebi görüntü içerisinde oransal olarak daha fazla miktarda özneliğin bu gemi çeşitleri için tespit edilmiş olmasıdır. Deneylerde

kullanılan her iki modele ait normalize edilmiş çapraz tahmin tabloları ve nesnel ölçüt tabloları incelendiğinde, tasarımsal olarak derin öğrenmenin gemi sınıflarının düzgün bir biçimde ayrıştırılarak doğru olarak sınıflandırılmasında uygun bir araç olduğunu göstermektedir. Başarımın veri büyüklüğüne doğru orantılı olarak arttığı görülmektedir. Modelden modele başarımlarının belirleyici bir unsur olduğu anlaşılmaktadır.

Tablo 2. Xception ile bulunan gemi çeşitleri için nesnel ölçüt değerleri (Objective metric values for ship variant detected by Xception)

Gemi Çeşitleri	Duyarlık	Anma	Doğruluk oranı
Aircraft	%98	%98	%99,73
Destroyer	%92	%94	%98,88
Containership	%99	%100	%99,88
Bulker	%97	%97	%99,54
Cargo	%98	%100	%99,81
Corvette	%94	%87	%98,58
Frigate	%93	%93	%98,85
Submarine	%99	%98	%99,85
Cruiser	%93	%95	%99,12
Tanker	%100	%96	%99,69
Ferrie	%99	%100	%99,88
Mine-warfare	%95	%99	%99,54
Fast-attack	%96	%96	%99,42
Bütün Sınıflar için Başarım Ortalama Değerleri	%96,38	%96,38	%99,44

Elde edilen sonuçlar, bu tarz bir gerçek zamanlı gemi sınıfı ayrıştırma ve sınıflandırma görevi için her iki model de kullanılabilir olduğu gösterse de Xception modeli daha yüksek başarımlar göstermesi nedeniyle tercih edilebilir konumdadır.

4. Sonuçlar (Conclusions)

Eğitilen her iki model için tablolarda verilen sonuçlar incelendiğinde her iki modelin de yaklaşık %96 ilâ %99 arası doğruluk oranında başarımlar elde ettiği görülmektedir. Elde edilen sonuçlar modellerin sınıflandırma adına oldukça kararlı ve başarımlarının yüksek olduğu anlaşılmaktadır. Her iki modelde de dikkat edilmesi gereken nokta; "Corvette", "Destroyer" ve "Frigate" tipindeki gemilere dair sınıfların çapraz tahmin matrisinde ve nesnel ölçüt değerlerinin diğer sınıflara göre ortalamasının altında

değer aldığıdır. Bunun nedenine baktığımızda ilgili gemilerin birbirine oldukça çok benzemesidir. Bunun önüne geçebilmek için iki yöntem denenebilir; veri kümesindeki veri sayısını artırmak veya her iki modele de Uzun Kısa Süreli Bellek (Long Short Term Memory, LSTM) katmanları eklenerek işlenen veri içerisindeki uzun süreli bağımlılıklara (veri blokları arası dolaylı ilişkilere) dair çıkarımların yapılabilmesi olarak bir çözüm ifade edilebilir. Gemilerin boyutlarına ve ortamın durumuna göre bir analiz yapılacak olursa; veri kümesinde bulunan görüntüler arasında gece çekilen, görüntü kalitesi düşük ve gemilerin küçük gözüktüğü görüntüler de bulunmaktadır. Nesnel ölçüt değerleri incelendiğinde, ortam veya gemi boyutunun belirli bir boyuta kadar küçülmesi tahmin işlemini aksatmamaktadır. Yapılan çalışmada klasik makine öğrenmesi yöntemine kıyasla, derin öğrenme modelleri kullanılması sayesinde, içeriğin anlamsal olarak

zenginleştirilmesi sağlanarak literatürdeki benzeri çalışmalara göre daha yüksek bir başarı oranı elde edilmiştir. İleriki çalışmalarımızda sistemin topluluk (ensemble) oluşturacak şekilde birden çok modelin melezlenmesiyle başarımın iyileştirilmesi hedeflenmektedir.

Rosenfeld, L., Morville P., Arango, J., 2015, Information Architecture for the web and beyond. O'Reilly Media, Inc. ISBN 9781491911686.
Zhenzhen, L., Baojun, Z., Linbo, T., Zhen, L. and Fan, F., 2019, Ship classification based on convolutional neural networks. The Journal of Engineering, 7343-7346. <https://doi.org/10.1049/joe.2019.0422>

Kaynaklar (References)

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G., Davis, A., Dean, J. et al., 2016, TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. Distributed, Parallel, and Cluster Computing (cs.DC); Machine Learning (cs.LG) arXiv Preprint, arXiv: 1603.04467.
- Cho M., 2013, Unsplash, <https://unsplash.com/>
- Chollet, F., 2016, Xception: Deep Learning with Depth wise Separable Convolutions, arXiv Preprints. arXiv:1610.02357v3
- Daniel Y.C., 2018, Pandas for Everyone: Python Data Analysis. Addison-Wesley, Boston: ISBN 978-0-13-454693-3.
- Dolapçı, B., Özcan, C., 2021. Automatic Ship Detection and Classification using Machine Learning from Remote Sensing Images on Apache Spark, Journal of Intelligent Systems: Theory and Applications, 4(2), 94-102.
- Getty, M., 2007, GettyImages, <https://www.gettyimages.com/>
- Harris, C.R., Millman, K.J., van der Walt, S.J. et al., 2020, Array programming with NumPy. Nature, 585, 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- Jiang P., Ergu, D., Liu, F., Cai, Y., Bo, M., A , 2022, Review of Yolo Algorithm Developments, Procedia Computer Science, 10(1), 1066-1073, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2022.01.135>.
- Karasulu, B., 2018. Kısıtlanmış Boltzmann makinesi ve farklı sınıflandırıcılarla oluşturulan sınıflandırma iş hatlarının başarımının değerlendirilmesi, Bilişim Teknolojileri Dergisi, 11(3), 223-233.
- LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., Jackel, L.D., 1989, Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation, 1(4), 541-551.
- Lekkas, D., 2007, Marine Traffic: <https://www.marinetraffic.com/en/ais/home/centerx:2.8>
- Livingstone, B., 2000, IStockPhoto, <https://istockphoto.com/>
- Lorica, B., 2017, Why AI and machine learning researchers are beginning to embrace PyTorch, O'Reilly Media.
- Lowe, D.G., 2004, Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision 60 (1), 91–110.
- Obrecht, C., 2014, Pexels, <https://www.pexels.com/>
- Reitz, K., A., 2022, Requests Python HTTP, <https://docs.python-requests.org/en/latest/>
- Richardson, L., 2021, Beautiful Soup Python Kütüphanesi. <https://www.crummy.com/software/BeautifulSoup/bs4/doc/>