

İçindekiler :

1. Projenin Amacı	<u>2</u>
2. Literatür Özeti	<u>2</u>
3. Konu Kapsam	<u>5</u>
3.1. Sosyal ve Politik Sorunlar	<u>5</u>
3.2. Sürdürülebilirlik	<u>6</u>
3.3. Maliyet Analizi	<u>6</u>
4. Projenin Hedefleri	<u>8</u>
5. Projenin Katkıları	<u>8</u>
6. Yöntem	<u>9</u>
6.1. Aşama 1	<u>9</u>
6.2. Aşama 2	<u>9</u>
6.3. Aşama 3	<u>10</u>
6.4. Aşama 4	<u>10</u>
7. İş Paketleri ve Zaman Çizelgesi	<u>12</u>
8. Araştırma Olanakları	<u>12</u>
9. Projenin Bütçesi	<u>13</u>
10. Kaynakça	<u>13</u>
11. Kabul Maili	<u>15</u>

1) Projenin Amacı:

Proje kapsamında, uydu görüntüleri kullanılarak derin öğrenme (deep learning) tabanlı yüksek tutarlılıkla gemi tespiti algoritmaları geliştirilmesi amaçlanmıştır. Bu sayede, özellikle deniz yetki alanı ihlalleri gibi milli güvenlik tehditleri, kaçak avcılık ve deniz kirliliğinin önüne geçilmesinin kolaylaşması beklenmektedir.

2) Literatür Özeti:

Meroufel et al. (2022) tarafından nesne tespitinde en iyi performans gösteren yöntem için derin öğrenme kullanılmıştır. Amaç ALSAT-2A multispektral görüntülerinden gemi tespiti için multimodal bir derin öğrenme çerçevesi geliştirilmesidir. İlk olarak, derin öğrenme modelinin sonuçları çoğunluk oylamalı bir füzyon tekniği (majority voting fusion technique) ile birleştirilmiştir. Önerilen modeller U-Net ve Maske Bölge-tabanlı Evrişim Sinir Ağı (Mask Region-based Convolution Neural Network: Mask R-CNN)'dir. Sonuçları geliştirmek için çoğunluk oylama (Majority Voting: MV) tekniği ile karar füzyonu yapılmıştır. MV oylama benzeri bir mekanizma ile birden çok çıktıdan gelen tahminleri birleştirir, çoğunluk oyu alan etiket tahmin edilir. Testler ALSAT-2A'dan alınan 2,5 m uzamsal çözünürlüğe sahip multispektral görüntü veri setleri kullanılarak yapılmıştır. Çalışma alanı Oran, Cezayir'dir. ALSAT-2 veri kümesi üzerinde her iki modelin de ayrı ayrı eğitildiği testler gerçekleştirilmiştir. Modeller, iki GPU (NVIDIA 1080-TI), 16 GB RAM ve CPU-i7 Intel ile donatılmış bilgisayarda TensorFlow çerçevesi kullanılarak eğitilmiştir. Her iki modelden (U-Net, Mask R-CNN) elde edilen sonuçları değerlendirmek için bu çalışmada üç değerlendirme ölçütü kullanılmıştır; Hassasiyet, Geri Çağırma ve F1 puanı. Değerlendirme sonuçlarında Mask R-CNN F1 skorunda en iyi doğruluğu elde ederken, U-Net ile daha düşük hassasiyet elde edilmiştir. Her iki ağın da geri çağırma performansı, karar birleştirme mekanizmasının performansı iyileştirebileceği durumlarda bağımsız tanıma için kullanılamayacaklarını ve ayrıca çoğunluk oylamasıyla karar birleştirme yoluyla daha iyi sonuçlar elde etmenin mümkün olması gerektiğini göstermektedir. Karar düzeyinde çoğunluk füzyonu ile kesinlik/hatırlama açısından iyi bir performans elde edilebileceği bulunmuştur [1].

Patel et al. (2022) tarafından trafik gözetim sistemleri, yasadışı balıkçılığın

önlenmesi, petrol deşarjının kontrol sistemleri ve deniz kirliliğinin izlenmesi için gerekli olan uydu görüntülerinden, derin öğrenme kullanılarak gemilerin otomatik olarak sınıflandırılması gerçekleştirilmiştir. Sistemi değerlendirmek için, hareket halindeki gemileri de içeren yaklaşık 40 bin uydu görüntüsünden oluşan, kamuya açık bir gemi veri seti üzerinde test edilmiştir. Veri seti gemi ve gemi dışı sınıfları için 80 x 80 piksel çözünürlüğe sahip 4 k RGB görüntüleri içerir. İlk olarak uydu görüntülerinden veriler hesaplanmıştır. Makalede kullanılan veri kümesi ve en güncel CNN algoritmaları (CNN, Bölge tabanlı CNN, ResNet, U-net) gözden geçirilmiştir. Daha sonra çeşitli derin öğrenme algoritmaları (YOLOv3, YOLOv4 ve YOLOv5) tanıtılır ve değerlendirilir. Geleneksel YOLOv5 algoritmasını kullanarak gemilerin başarılı bir şekilde tespiti ve YOLOv3 ve YOLOv4 arasında elde edilen sonuçların güncel ve iyi bilinen CNN mimarileri ile karşılaştırılmıştır. F1 puanı ve mAP, üç YOLO ailesi algoritmasının, yani YOLOv3, YOLOv4 ve YOLOv5'in performansını karşılaştırmak için kullanılmıştır. YOLOv5'in uydu görüntülerinden gemileri tespit etmede en yüksek doğruluğa sahip olduğu için en iyisi olduğu sonucuna varılabilir. Algoritmalar sonuçları doğrulamak için bir bilgisayarda değerlendirilir. Test edildiğinde YOLOv3 %97, YOLOv4 %98 ve YOLOv5 %99 tespit doğruluğu gösterdiği gözlemlendi. Gelecekteki araştırma hatları, geminin yerini belirlemek için konum özelliklerinin nesne algılama/sınıflandırma şemasına dahil edilmesine odaklanılacaktır [2].

Dolapcı ve Özcan (2021) tarafından, yüksek performanslı bir sınıflandırma ve gemi tespit işlemleri için hibrit bir vektör geliştirilmiştir. Amaç, görüntünün tüm ayırt edici özelliklerini bir vektör uzayında birleştirmek ve doğru sonucu üretecek anlamlı bir özellik vektörü oluşturmaktır. Bu çalışmada öncelikle görüntülere blok kesit uygulanmıştır. Bu adımdan sonra, renk ve doku öznitelikleri çıkarılarak eğitim verisi olarak kullanılmak üzere görüntü bloklarından öznitelikler çıkarılmıştır. Bu özellikler, bir hibrit özellik vektörü oluşturmak için birleştirilir. Daha sonra, Naive Bayes, Karar Ağacı ve Rastgele Orman sınıflandırıcıları, daha önce çıkarılan öznitelik vektörlerine dayalı olarak eğitilir. Sınıflandırıcılar eğitildikten sonraki adım olarak, test görüntülerinin blokları üzerinde gemi blokları ve gemi dışı bloklar arasında sınıflandırma yapılmıştır. En yüksek başarı %99,62 ile Rastgele Orman yöntemi olmuştur. Değerlendirilen üç renk alanı arasındaki karşılaştırmalı çalışmada, HSV+SD+FS+GLCM öznitelik vektörü en yüksek performans oranına ulaşılmıştır.

Renk ve doku özellikleri birlikte kullanıldığında daha yüksek başarı elde edildiği gözlemlenmiştir [3].

Stofa et al. (2020) tarafından, uydu görüntülerine dayalı olarak gemi varlığının tespiti ve sınıflandırılmasında yüksek doğruluk elde edilmeye çalışılmıştır. Uzaktan algılama görüntüleri için DenseNet kullanan bir gemi tespit ve sınıflandırma yöntemi önerilmiştir. DenseNet, gemileri %90'dan fazla doğrulukla sınıflandırabilen son derece gelişmiş bir algoritmadır. Parti boyutu, bir eğitim yinelemesi için işlenen örnek sayısını tanımlayan bir hiper parametredir. En iyi hiperparametre kombinasyonu, parti boyutu 16 ve öğrenme oranı 0,0001 kullanıldığında elde edilir. DenseNet'i eğitmek için ve parametreleri kayıp fonksiyonuna göre güncellemek için bir optimizasyon algoritmasına ihtiyaç vardır. Adam optimizer %98,44 doğrulukla, DenseNet kullanarak gemi algılamamız için en iyi optimizasyon yöntemi olarak da bulunmuştur [4].

Zhang ve Xu (2016) tarafından, uzaydan Dünya gözlemlerinde daha yüksek bir sinyal-gürültü oranı elde edebildikleri için tercih edilen Pushbroom görüntüleme spektrometreleri multimodal olarak incelenmiştir. Çözünürlük arttıkça tatmin edilmesi zorlaşan Pushbroom kamerasının görüntü alımı sırasında uydunun sabit olması çok önemlidir. JL-1 uydusuna monte edilen pushbroom sensörleri, kısa gözlem aralığı ile bantlar arasında küçük paralaks oluşturur. Bu paralaks gözlem sisteminde farklı sensörler aynı noktayı sabit aralıklarla gözlemler. JL-1 uydusunun pushbroom sistemi spektrumun kırmızı, mavi, yeşil ve pankromatik bölgesinde ayrı ayrı dört bant üzerinde çalışan dört doğrusal dizi dedektöründen oluşur. Her bitişik bant arasındaki mesafe yaklaşık $5 \cdot 10^{-3}$ m'dir ve sensör aynı noktayı 0,03 sn'de bir tarar. Makaledeki çalışmanın özgünlüğü, multispektral pushbroom görüntüleri için geliştirilmiş ve gerçek zamanlı bir kayıt algoritması sunmasıdır. Bu yöntem, görüntü elde etme sırasında tutum değişikliğini algılayabilir ve düzeltebilir. Sonuçlar, JL-1 uydu görüntü ürünleri için geometrik işleme doğruluğunda iyileştirme olasılığını gösterir ve uydu platformu titreşim kaynak analizi için iyi bir referans sağlar [5].

Duman (2019) tarafından açık kaynak kodlu Tensorflow Nesne Tespiti API'i eğitilerek optik uydu görüntülerinden gemi algılama algoritmalarına ilave bir seçenek eklenmiştir. Çalışmada, derin öğrenme kütüphanesi olarak Tensorflow, bilgisayarlı görü kütüphanesi olarak OpenCV kütüphaneleri kullanılmıştır. Tek bir

nesne algılama modelinin eğitiminin, haftalar ve hatta aylar sürebileceği; önceden eğitilmiş bir modelin kullanımının ve tespit edilmek istenen nesne için eğitilmesinin ise çok daha faydalı ve hızlı bir yöntem olacağı aktarılmıştır. Bu bağlamda, Google tarafından eğitilmiş olan Tensorflow Nesne Algılama Uygulama Programlama Arabirimi (Tensorflow Object Detection Application Programming Interface (API)), önceden eğitilmiş nesne tespit modeli olarak kullanılmış olup, içlerinde gemi barındıran optik uydu görüntüleri ile eğitilmiştir (Tensorflow Object Detection API, 2019). Modelin belirlenmesine müteakiben modelin eğitiminde kullanılacak gemi görüntü setleri internet ortamından indirilmiştir (Rhammell, 2019). Görüntü seti, çözünürlüğü 80 * 80 * 3, RGB bandı, 96 dpi olan 2085 adet görüntüden oluşur. Eğitim basamağında model; gemi etiketli eğitim resimleri ile kendisini eğitmekte ve test görüntülerindeki gemileri tespit etmeye çalışmaktadır. Tespit sonuçları ile test resimlerindeki işaretlenmiş gemiler karşılaştırılmakta, daha iyi tespit sonucu için model otomatik olarak nöron katsayılarını güncellemek suretiyle eğitimi tekrarlamakta ve en iyi tespit performansına ulaşmaya çalışmaktadır. Denenen modeller arasında “faster rcnn inception v2_coco” modelinin öğrenim oranının on kat azaltılmış halinin (kayıp grafik rengi açık mavi olan) en iyi tespit performansına sahip olduğu gözlenmiştir [6].

Abujayyab et al. (2020) tarafından Göktürk-2 uydusundan alınan görüntüler kullanılarak Derin Evrişim Sinir Ağı (Deep Convolution Neural Network: DCNN) modeli kullanılarak bir gemi tespit algoritması geliştirilmiştir. DCNN modelinin eğitimi için MATLAB platformu, uydu görüntülerini işlemek için ise ArcMap platformu kullanılmıştır. Modeli eğitmek için “Ankara Keşif Uydu Komutanlığı”ndan alınan 300 GB yer kaplayan uydu görüntüleri kullanılmıştır. Çalışmalar sonucunda %83,33 başarı oranı ile gemi tespiti gerçekleştirilmiştir [7].

3) Konu/Kapsam:

Deniz yetki alanı ihlalleri, yüzyıllardır birçok devletin milli güvenlik sorunu olmuştur ve birçok savaşa veya diplomatik krize neden olmuştur. Bu bakımdan devletlerin deniz yetki alanlarının güvenliği her zaman için son derece kritik olmuştur. Bunlara ek olarak; gemi trafiğinin takibi, kaçak avcılığın önlenmesi, deniz kirliliğinin önlenmesi ve kayıp gemi/tekne gibi durumlar da her zaman için

devletlere büyük yük oluşturmuştur. Bu sorunların ortadan kaldırılması için ve deniz yetki alanının güvenliğinin sağlanması için uydu sistemleri kritik rol oynamaktadır. Uydular vasıtasıyla deniz yetki alanları izlenebilmekte ve görüntüler gözetleme, keşif ve istihbarat gibi amaçlarla kullanılmaktadır.

Çalışmamızın kapsamı, deniz yetki alanlarının güvenliği için uydu görüntülerinin derin öğrenme modelleri ile işlenmesi ve gemilerin yüksek doğrulukla tespitinin sağlanmasıdır. Bu bağlamda, yeni algoritmalarının geliştirilmesi ve var olan algoritmaların hız, doğruluk gibi parametrelerinin güçlendirilmesi hedeflenmektedir.

Derin öğrenme modellerinde iki farklı yaklaşımın var olduğu görülmüştür. Bu yaklaşımlar unimodal (tek kipli) ve multimodal (çok kipli) derin öğrenme modelleridir. Unimodal derin öğrenme yaklaşımında, model tek bir giriş tipinde veri ile eğitilerek oluşturulur. Bu açıdan hız, daha düşük sistem gereksinimleri gibi nedenlerden dolayı daha çok tercih edilmektedir. Multimodal derin öğrenme yaklaşımında ise, model birden fazla giriş tipinde veri ile eğitilerek oluşturulmaktadır. Bu nedenle, modelin eğitilmesi daha çok zaman almakta ve gerekli sistem gereksinimleri daha yüksek olmaktadır. Ancak, multimodal derin öğrenme yaklaşımı yüzde 6-10 oranında daha yüksek doğruluk payına sahiptir. Projemizin hedeflerinden biri de modelin çıktısının doğruluk payının yüksek olmasıdır. Bu bakımdan, uygun veri setlerinin elde edilebilmesi durumunda multimodal derin öğrenme yaklaşımı kullanılacaktır. Bu sayede doğruluk oranı daha da artacak ve yanlış tespit halinde oluşacak zaman, maliyet kayıplarının önüne geçilebilecektir. Aşağıda çalışmanın bazı mühendislik kısıtlarına göre analizi yer almaktadır:

1. Sosyal ve Politik Sorunlar: Çalışma, başarılı bir şekilde gerçekleşirse sosyal ve politik olarak ülkemize birçok katkısı bulunacaktır. Özellikle, Ege Denizi ve Karadeniz'deki güncel siyasi konjonktür, bu tür teknolojilerin aktif kullanımını ve sürekli olarak geliştirilmesini elzem kılmaktadır.
2. Sürdürülebilirlik: Projede yüksek performanslı bilgisayarlar ve elektronik ekipmanlar kullanılacaktır. Derin öğrenme hesaplamaları yapılırken bilgisayarın güçlü bir CPU'ya ihtiyacı olur, çünkü çok sayıda hesaplama yapılması gerekmektedir. Çok sayıda hesaplama fazla güç harcanmasına sebep olacaktır. Bilgisayarların RAM'i arttıkça işleyebileceği veri miktarı artar. Daha fazla veri

öğretilmesi, daha yüksek doğruluk oranı demektir. Taşınma kolaylığı açısından dizüstü bilgisayar kullanılacaktır. Dizüstü bilgisayarlar, masaüstü bilgisayarlara oranla daha az enerji tüketirler. Standart bir dizüstü bilgisayarın üretim sürecinde yaklaşık 500 ila 594 pound karbondioksit salınır. Yeni bir dizüstü bilgisayar genellikle masaüstü eşdeğerinden yaklaşık yüzde 80 daha az elektrik tüketir. Dizüstü bilgisayarlar tipik olarak maksimum 60 Watt çekerken, standart masaüstü bilgisayarlar 175 Watt civarında zirve yapabilirler. Genel olarak katı hal sürücülü (SSD) depolamaya sahip daha yeni dizüstü bilgisayarlar daha hızlı çalışır ve daha az enerji tüketirler. Bilgisayarın üretim süreci ürünün çevresel ayak izinin büyük bir ölçüsünü kaplar. Dizüstü bilgisayarın ekolojik etkisinin yalnızca yüzde 20'sinin kullanım kaynaklı olduğuna inanılmaktadır. Geri kalan çevresel ayak izini oluşturan kısım ise üretim ve dağıtım sürecinin alt süreçlerinden kaynaklanmaktadır. Bu alt süreçler aşağıda listelenmiştir:

- Bilgisayarın parçalarına giren çok sayıda metal ve diğer hammaddelerin madencilik süreçleri.
- Malzemeleri üretim için fabrikaya getiren uzun tedarik zinciri.
- Gerçek üretim sürecinde kullanılan enerji ve malzeme türleri.
- Dizüstü bilgisayarı son kullanıcıya teslim etmek için kullanılan dağıtım ağı.

Derin öğrenme için ihtiyaç duyulan yüksek performanslı bilgisayarların ve diğer elektronik ekipmanların sürdürülebilirlik açısından iyi yanı, çoğu parçanın geri dönüştürülebilir olmasıdır. Genel olarak, bir dizüstü bilgisayarın tüm parçaları özel tesislerde geri dönüştürülebilir. Cam monitör, klavye, plastik veya alüminyum kasa, kablolar, CD-ROM sürücüsü, ışın tüpü, güç kablosu, devre kartı, piller ve yazıcı kartuşlarının tümü geri dönüştürülebilir bilgisayar malzemeleridir. Dizüstü bilgisayarın anakartlar ve sabit diskler gibi bazı elektronik parçaları satılabilir ve yenilenmiş ürünlerde yeniden kullanılabilir. Dizüstü bilgisayar bataryaları belirli bir şekilde çıkarılıp geri dönüştürülmeleri gerekir. Geri dönüşüm yapılmaması halinde elektroniklerin içerebilecekleri camın ayrışması 1-2 milyon yıl sürebilmektedir.

3. Maliyet Analizi:

Projenin maliyet analizi Şekil 1’de yer almaktadır.

Gereksinimler	Özellikler	Maliyet
Bilgisayar	RAM Memory: 32GB Operating System: Windows 11 CPU: Intel Core i7 Grafik İşlemci: NVIDIA GeForce	54000 TL
Mouse		2878 TL
Klavye		720 TL
Mühendis Maaşları	3 mühendis * 8 ay * (16200 TL)	388800 TL
Toplam Maliyet		446398 TL

Şekil 1. Maliyet Analizi

4) Projenin Hedefleri:

Proje TUSAŞ ile sanayi destekli olarak gerçekleştirilecektir. Beraber çalışılacak olan firmanın istekleri doğrultusunda hedefler konusunda eklemeler yapılabilir. Projede çok kipli (multimodal) uydu görüntülerinden derin öğrenme tabanlı gemi tespiti yapılması amaçlanmaktadır.

Projede, modelin gemi tespitinde %90 doğruluk oranı elde edilmesi hedeflenmektedir. Farklı hava koşullarında algoritmaların verdiği sonuçlar karşılaştırılıp iyileştirme yapılacaktır. Ayrıca derin öğrenme algoritmalarının çalışması sırasında performansa oranla hız kaybının azaltılması hedeflenmektedir.

Multimodal uydu görüntülerine erişim olması durumunda farklı açılardan görüntü elde edilmesiyle nesne tespitinde hata oranının azaltılması amaçlanmaktadır.

5) Projenin Katkıları:

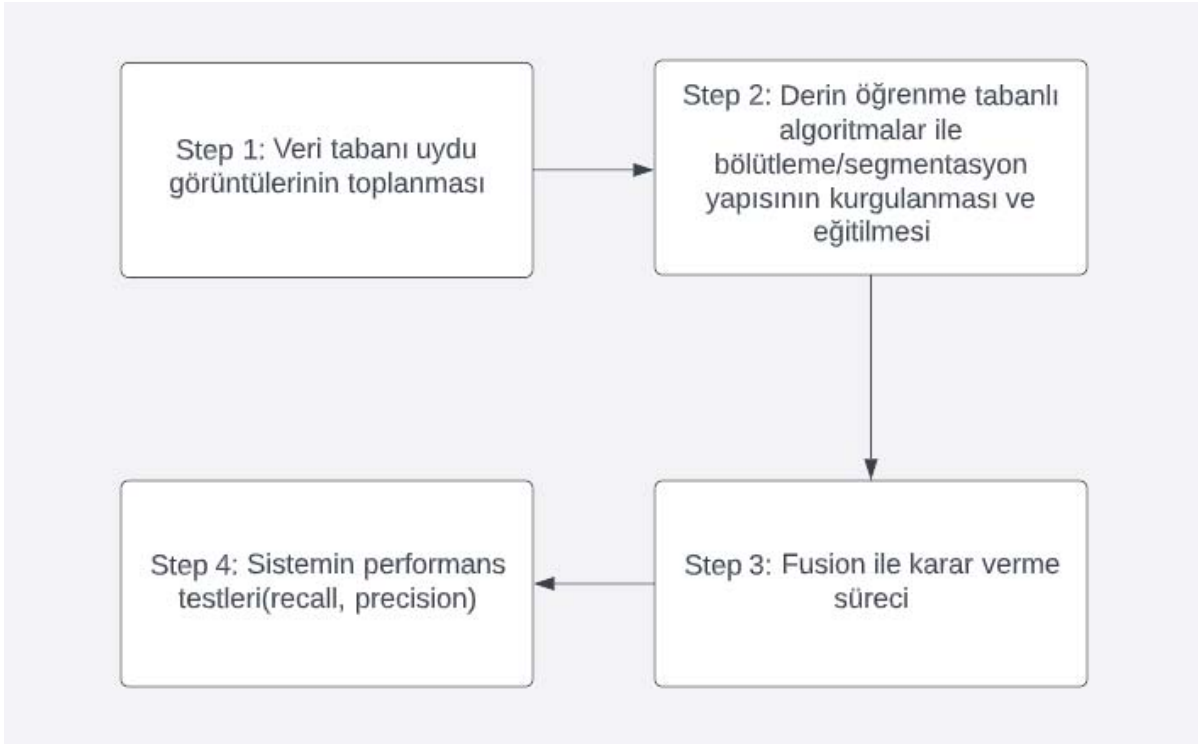
- Uydu görüntülerinden derin öğrenme ile gemi tespiti yaparken farklı bölütleme algoritmaları denenecek ve performansları karşılaştırılacaktır.
- Diğer çalışmalara ek olarak gerekli veri setlerine erişim sağlanabildiği taktide derin öğrenme algoritmaları geliştirilirken multimodal uydu görüntüleri kullanılacaktır. Bu sayede modelin doğruluk payının artırılması

hedeflenmektedir.

- Deniz yetki alanı ihlalleri gibi milli güvenlik tehditlerinin önüne geçilmesinin ayrıca deniz kirliliğine neden olan gemiler, kaçak balıkçılık gibi ekolojik dengeyi bozan unsurların tespitinin sağlanması hedeflenmektedir.

6) Yöntem:

Projede tasarlanacak sistemin blok diyagramı Şekil 2’de verilmektedir.



Şekil 2. Sistemin Blok Diyagramı

1. Veri Tabanı Verilerinin Toplanması: Projenin ilk aşamasına, veri tabanı uydu görüntülerinin toplanması ile başlanacaktır. Literatür taramalarında edindiğimiz bilgilere göre bu tür çalışmalar için açık kaynaklı birçok uydu görüntüsü yer almaktadır. Özellikle Kaggle ve GitHub gibi platformlarda birçok farklı uydudan elde edilmiş çok sayıda veri seti bulunmaktadır. Halihazırda Kaggle.com’den eriştiğimiz 13,4 GB büyüklüğünde HRSC2016 adında, 1680 adet uydu görüntüsü içeren bir veri setine sahibiz. Projeyi TUSAŞ ile gerçekleştirileceği için TUSAŞ tarafından da veri setleri paylaşılacaktır.
2. Derin Öğrenme Tabanlı Algoritmalar ile Bölütleme/Segmentasyon Yapısının Kurgulanması ve Eğitilmesi: Projenin ikinci aşamasında, projemizin belki de temelini oluşturan derin öğrenme algoritmaları oluşturulacak ve bu algoritmalar ile bölütleme/segmentasyon yapısı kurgulanacaktır. Bunların ardından model

eğitilecek ve görselden gemiyi algılama becerisi elde etmesi sağlanacaktır. Derin öğrenme, bilgisayarların edinilmiş tecrübe ve bilgilerden istenilen şeyleri öğrenmelerini ve ham verilerden faydalı kalıpları çıkarmasını sağlayan bir tür makine öğrenmesi yöntemidir. Birçok derin öğrenme yönteminde yapay sinir ağları kullanılmaktadır. Bu ağlar girdi (input), gizli (hidden) ve çıktı (output) katmanlarından oluşmaktadır. Her katmandaki nöronların sayısı birden fazla olabilese de, ağır öğrenme yeteneği üzerinde en fazla etkiye sahip olan katmanı gizli katmandır [6]. Projede, gemi tespit algoritma ve yazılımının kaynak kodunun Python dilinde yazılması planlanmaktadır. Derleyici olarak açık kaynaklı Anaconda, Pycharm, Visual Studio Code gibi IDE'lerden en avantajlı araçları sunan IDE seçilecektir. Derin öğrenme kütüphanesi olarak Google tarafından oluşturulmuş Tensorflow kütüphanesi, bilgisayarlı görü (computer vision) kütüphanesi için ise OpenCV kütüphanesinin kullanılması planlanmaktadır. Nesnelerin tespiti için aranan nesnelerin özelliklerinin saklandığı bir özellik kütüphanesine ihtiyaç duyulur. Bu kütüphane yeni baştan oluşturulabileceği gibi daha önceden eğitilmiş bir kütüphane de kullanılabilir. Nesne algılama modeli bu kütüphaneyi içinde barındırıp bu kütüphane ile beraber eğitilebilir. Tek bir nesne algılama modelinin eğitimi, Grafik İşlemci Ünitesi (GPU)'nde bile haftalar hatta aylar sürebilir. Bahse konu eğitim, Merkezi İşlem Birimi (CPU) için çok daha uzun süreler alabilir. Önceden eğitilmiş bir modelin kullanımı ve istenilen nesne için eğitilmesi ise çok daha faydalıdır ve zamandan tasarruf sağlar [6]. Projede de zaman ve enerjiden tasarruf sağlamak adına Google tarafından eğitilmiş olan Tensorflow Nesne Algılama Uygulama Arabirimi (Tensorflow Object Detection API) kullanımı planlanmaktadır. Ancak projenin beraber geliştirileceği TUSAŞ'tan aksi bir talep gelirse projenin bu aşamasında kullanılacak yöntemlerde değişikliğe gidilebilir.

3. Füzyon ile Karar Verme Süreci: Projenin üçüncü aşamasını füzyon ile karar verme süreci oluşturur [8]. Karar füzyonu, sınıflandırıcıların bireysel kararlarından daha iyi olan ortak bir fikir birliğine ulaşmak için farklı sınıflandırıcılar tarafından alınan kararları birleştirmeyi amaçlar. Burada sınıflandırıcının kararı, test veri setinde gerçekleştirilen sınıflandırmadır [9]. Farklı yöntemlerden, algoritmalarından, kaynaklardan veya sınıflandırıcılardan elde edilen sonuçlar, tek başına herhangi bir kaynaktan elde edilebilecek olandan daha iyi kalitede tahminler vermek için birleştirilir. Bu projede karar füzyon mekanizması ile performansı iyileştirilmiş sonuçlar elde edilmesi amaçlanmıştır. Çalışmada veri birleştirme ile karar verme teknikleri gözden geçirilecek ve kullanılacaktır. Bu tekniklerden biri [1] çoğunluk oylamasıdır (MV). Sık olarak geç birleştirme yaklaşımlarında tanımlanabilir. Bu teknik, ideal olarak sette kullanılan herhangi bir tek modelden daha iyi performansa sahip olan çerçevelerin verimliliğini artırmak için kullanılabilir. MV, çeşitli modellerden gelen tahminleri birleştirmek için oylama benzeri bir mekanizma ile birden çok çıktıdan gelen tahminleri birleştirir. Sınıflandırma görevlerinde, her bir etiket için tahminler toplanır ve çoğunluk oyu alan etiket tahmin edilir.
4. Sistemin Performans Testleri (Recall, Precision): Hata matrisi, verideki var olan durum ile sınıflama modelimizin doğru ve yanlış tahminlerinin sayısını gösterir. [10]

<i>Confussion Matrix</i>		Gerçek (Actual) Sonuçlar	
		Pozitif (1)	Negatif (0)
Tahminlenen (Predicted) Sonuçlar	Pozitif (1)	TP [1, 1] True Pozitif	FP [1, 0] False Pozitif
	Negatif (0)	FN [0, 1] False Negatif	TN [0, 0] True Negatif

Şekil 3. Hata matrisi (Yiğit Şener, “Veri Bilimi Sınıflandırma Model Çıktılarını Değerlendiren Metrikler“, Aug 13, 2020)

- TP (True Positive — Doğru Pozitif): Gemi varken “gemiye tespit eder.”
- FP (False Positive — Yanlış Pozitif): Gemi yokken “gemiye tespit eder.”
- TN (True Negative — Doğru Negatif): Gemi yokken “gemiye tespit edemez.”
- FN (False Negative — Yanlış Negatif): Gemi varken “gemiye tespit edemez.”
- Doğruluk (Accuracy): Sistemde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır. Tek başına güvenilir bir karşılaştırma kriteri değildir.

$$\text{Doğruluk} = (TP+TN) / (TP+TN+FN+FP)$$
- Duyarlılık (Recall): Pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarını pozitif olarak tahmin edildiğini gösteren bir ölçüttür.

$$\text{Duyarlılık} = TP / (TP + FN)$$
- Kesinlik (Precision): Pozitif olarak tahminlenen değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir.

$$\text{Kesinlik} = TP / (TP + FP)$$

7) İş Paketleri ve Zaman Çizelgesi:

Projenin iş paketleri ve zaman çizelgesi Şekil 4'te verilmiştir.

	EKİM	KASIM	ARALIK	OCAK	ŞUBAT	MART	NİSAN		MAYIS
							15	30	
LİTERATÜR TARAMASI									
VERİTABANI OLUŞTURULMASI									
YAPININ KURGULANMASI VE EĞİTİLMESİ									
FUSİON İLE KARAR VERME SÜRECİ									
TESTLER									
RAPORLANDIRMA SÜRECİ									

Şekil 4. İş Paketleri ve Zaman Çizelgesi

8) Araştırma Olanakları:

- Bu proje savunma sanayiinde faaliyet gösteren TUSAŞ firması ile birlikte gerçekleştirilecektir. Dolayısıyla projenin teknik özellikleri firmasının istekleri doğrultusunda da belirlenecektir. Firmanın olanaklarından da faydalanılacaktır.

- Bu projede kullanılacak akademik makaleler için Google Scholar, Elsevier, ScienceDirect ve IEEE Explore'dan faydalanılacaktır. Ayrıca, GitHub platformunda derin öğrenme için örnek algoritmalar incelenebilir ve StackOverflow gibi forumlardan yardım alınacaktır.

- Derin öğrenme çalışmalarında kullanılan birden fazla kütüphane ve yazılım bulunmaktadır. Bunun için PyTorch, TensorFlow gibi Python kütüphanelerinden yararlanılabilir. Kodların derlenmesi için kullanılacak ortam (IDE), kullanım avantajları ve dezavantajları göz önünde bulundurularak, açık kaynak kodlu Anaconda Python, PyCharm, Visual Studio Code gibi seçenekler değerlendirildikten sonra seçilecektir.

- Modelin eğitilmesi için gerekli veri setleri için, açık kaynak, Kaggle ve GitHub gibi platformlar değerlendirilecektir.

9) Projenin Bütçesi:

Projenin bütçesi Şekil 5’te yer almaktadır.

Gereklilikler	Ücret-Fiyat	Adet-Süre	Toplam
Bilgisayar	27000 TL	2	54000 TL
Mouse	1439 TL	2	2878 TL
Klavye	360 TL	2	720 TL
Mühendis Maaşları	90 TL	1 saat	388800 TL (8 ay için)
Proje Toplam Maliyet	446398 TL		

Şekil 5. Projenin Bütçesi

10) Kaynakça:

- [1] H. Meroufel, M. El Amin Larabi and M. B. Amri, "Deep Learning Based Ships Detections from ALSAT-2 Satellite Images," 2022 IEEE Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), 2022, pp. 86-89, doi: 10.1109/M2GARSS52314.2022.9839871.
- [2] K. Patel, C. Bhatt, and P. L. Mazzeo, "Deep Learning-Based Automatic Detection of Ships: An Experimental Study Using Satellite Images," *Journal of Imaging*, vol. 8, no. 7, p. 182, Jun. 2022, doi: 10.3390/jimaging8070182.
- [3] B. Dolapçı and C. Özcan, "Automatic Ship Detection and Classification using Machine Learning from Remote Sensing Images on Apache Spark", *Journal of Intelligent Systems: Theory and Applications*, vol. 4, no. 2, pp. 94-102, Sep. 2021, doi:10.38016/jista.772145
- [4] Mohd Stofa, Marzuraikah & Zulkifley, Mohd Asyraf & Zaki, Siti. (2020). A deep learning approach to ship detection using satellite imagery. *IOP Conference Series: Earth and Environmental Science*. 540. 012049. 10.1088/1755-1315/540/1/012049.
- [5] Z. -X. Zhang and G. -D. Xu, "Detection of JL-1 satellite's jitter using multimodal pushbroom cameras," *2016 7th International Conference on Mechanical and Aerospace Engineering (ICMAE)*, 2016, pp. 638-642, doi: 10.1109/ICMAE.2016.7549616.
- [6] O. Duman, M. Kartal, "Derin Öğrenme Yöntemi ile Optik Uydu Görüntülerinden Gemi Tespiti", Master Thesis, Communication Systems Department, Istanbul Technical University, Turkey, 2019

- [7] E. Suel, S. Bhatt, M. Brauer, S. Flaxman, και M. Ezzati, ‘Multimodal deep learning from satellite and street-level imagery for measuring income, overcrowding, and environmental deprivation in urban areas’, *Remote Sensing of Environment*, τ. 257, σ. 112339, 2021.
- [8] Yashvi Chandola, “End-to-end pre-trained CNN-based computer-aided classification system design For chest radiographs”, sciencedirect.com Available: <https://www.sciencedirect.com/topics/computer-science/decision-fusion-technique> [Accessed Oct. 8, 2022].
- [9] “What is Decision Fusion | IGI Global”, Igi-global.com, Available: <https://www.igi-global.com/dictionary/decision-fusion-multisensor-images-human/6992> [Accessed Oct. 8, 2022].
- [10] Erdinç Uzun, “Model Başarısı Değerlendirme – Sınıflandırma”, erdincuzun.com, Available: https://erdincuzun.com/makine_ogrenmesi/model-degerlendirme-siniflandirma/. [Accessed Oct. 8, 2022].