

**T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜREV TABANLI YÖNTEMLER KULLANARAK SAR GÖRÜNTÜLERİNDE
GEMİ TESPİTİ**

YÜKSEK LİSANS TEZİ

Hasan Can ÖZBEK

Yazılım Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Kazım HANBAY

TEMMUZ 2026

**T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜREV TABANLI YÖNTEMLER KULLANARAK SAR GÖRÜNTÜLERİNDE
GEMİ TESPİTİ**

YÜKSEK LİSANS TEZİ

**Hasan Can ÖZBEK
(36243632002)**

Yazılım Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Kazım HANBAY

TEMMUZ 2026

TEŞEKKÜR VE ÖNSÖZ

Bu tez çalışmasının her aşamasında engin bilgi birikimini, değerli tecrübelerini ve rehberliğini cömertçe paylaşan danışman hocam Sayın Prof. Dr. Kazım HANBAY'a en içten şükranlarımı sunarım. Çalışmanın başlangıcından itibaren kurduğumuz sürekli iletişim ve hocamın her konudaki yönlendirici desteği, bu tezin şekillenmesinde belirleyici bir rol oynamıştır. Gösterdiği sabır, akademik titizlik ve her an ulaşılabilir olma anlayışı, zorlu süreçlerde bana her zaman güç vermiştir.

Araştırma sürecinde takıldığım noktalarda deneyimleriyle yol gösteren ve çözüme kavuşmamda katkısı olan Arş. Grv. Çetin ERÇELİK'e de içtenlikle teşekkür ederim. Paylaştığı deneyimler ve pratik yaklaşımı, karşılaştığım güçlüklerin aşılmasında değerli bir katkı sağlamıştır.

Tez çalışmaları, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 123E344 numaralı proje kapsamında desteklenmiştir. Sağlanan maddi destek ve araştırma olanakları için TÜBİTAK'a teşekkür ederim.

Ayrıca bu sürecin her anında yanımda olan, manevi desteklerini hiçbir zaman esirgemeyen ve varlıklarıyla bana güç veren aileme sonsuz minnet ve şükranlarımı sunarım.

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduğum “Türev Tabanlı Yöntemler Kullanarak Sar Görüntülerinde Gemi Tespiti” başlıklı bu çalışmanın bilimsel ahlaka ve araştırma etiğine uygun olarak, dışarıdan yardım almadan tarafımdan yazıldığını ve kullandığım kaynakların tümünün metin içinde ve kaynakçada doğru şekilde referanslandığını beyan ederim. Bu çalışmanın bilimsel bir değer taşımasını umar ve ilerleyen dönemlerde daha da nitelikli çalışmalar üreteceğime olan taahhüdümü ifade ederim. Bilim dünyasına katkı sağlama fırsatı için heyecan duyuyorum.

Hasan Can ÖZBEK



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ	i
ONUR SÖZÜ	ii
İÇİNDEKİLER.....	iii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	iv
ŞEKİLLER DİZİNİ.....	v
SEMBOLLER VE KISALTMALAR	vi
ÖZET	vii
ABSTRACT	viii
1. GİRİŞ	1
1.1 SAR Görüntü Elde Etme	2
1.1.1 Gaofen uydusu	3
1.1.2 Sentinel 1	3
1.2 Literatürde Yapılan Çalışmalar	4
1.3 Tezin Amacı	11
2. YENİ SAR GEMİ VERİ TABANI.....	12
2.1 Üretilen SAR Gemi Veri Tabanı	15
3. MATERYAL VE METOT.....	27
3.1 Gaussian Olasılığı ve Özdeğer Analizine Dayalı Model ile Gemi Tespiti.....	28
3.2 Derin Öğrenme Modelleri	32
3.2.1 You Only Look Once (YOLO).....	33
3.2.2 YOLOv26 Model Mimarisi	35
3.2.3 YOLOv12 Model Mimarisi	36
3.2.4 Eğitim Parametreleri.....	37
3.2.5 Eğitim Aşaması	38
4. UYGULAMA VE DEĞERLENDİRME.....	40
4.1 Sınıflandırıcı Parametreleri.....	40
4.2 Değerlendirme Metrikleri	40
4.3 Gaussian Olasılığı ve Özdeğer Analizine Dayalı Model ile Alınan Sonuçlar.....	42
4.4 Derin Öğrenme Modelleri ile Alınan Sonuçlar	45
5. SONUÇLAR VE ÖNERİLER	50
KAYNAKLAR.....	52

ÇİZELGELER DİZİNİ

Çizelge 2.1: Literatürdeki Gemi Veritabanları	15
Çizelge 2.2: Uydu verilerinin kullanım alanları ve özellikleri.....	16
Çizelge 2.3: Polarizasyon türleri ve görüntüleme modlarının özellikleri	19
Çizelge 3.1: Eğitim parametreleri.	37
Çizelge 3.2: Eğitim için verilerin dağılımı.	38
Çizelge 4.1: Önerilen Model için elde edilen metrikler.	43
Çizelge 4.2: Yolov26 için elde edilen metrikler.....	46
Çizelge 4.3: Yolov12 için elde edilen metrikler.....	47



ŞEKİLLER DİZİNİ

Şekil 1.1: SAR veri tabanından görüntüler.	4
Şekil 2.1: Literatürdeki bazı SAR veri setlerinden görüntüler.	13
Şekil 2.2: Veri indirme süreçleri.	20
Şekil 2.3: Ön işleme sonucu elde edilen görüntü.	21
Şekil 2.4: Veritabanı oluşturulma süreci.	22
Şekil 2.5: Parçalanmış bir uydu görüntüsü.	23
Şekil 2.6: Parçalanmış görüntülerin nihai halleri.	24
Şekil 2.7: Görüntülerin etiketlenme süreci.	25
Şekil 2.8: Etiketlenmiş örnek bir gemi nesnesi.	25
Şekil 3.1: Morfolojik işlemler sonucu oluşan ikili siyah-beyaz görüntüler.	30
Şekil 3.2: Tespit edilmesi beklenen gemi nesneleri.	31
Şekil 3.3: YOLOv26 sistem mimarisi.	35
Şekil 3.4: YOLOv12 sistem mimarisi.	36
Şekil 3.5: Python ile model eğitimi.	39
Şekil 4.1: Karmaşıklık matrisi.	41
Şekil 4.2: Sonuçların diğer yöntemlerle kıyaslanması.	44
Şekil 4.3: YOLO modellerinin tespit ettiği gemiler.	48
Şekil 4.4: Yolov26'ın ürettiği doğrulama görüntüsü.	49

SEMBOLLER VE KISALTMALAR

SAR	: Synthetic Aperture Radar
ESA	: European Space Agency
SSDD	: Sar Ship Detection Dataset
IW	: Interferometric Wide
CNN	: Convolutional Neural Network
σ	: (Sigma) Gauss fonksiyonun Standart sapması
TP	: Doğru Pozitif
NT	: Doğru Negatif
FP	: Yanlış Pozitif
FN	: Yanlış Negatif

ÖZET

Yüksek Lisans Tezi

TÜREV TABANLI YÖNTEMLER KULLANARAK SAR GÖRÜNTÜLERİNDE GEMİ TESPİTİ

Hasan Can ÖZBEK

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

55+VIII sayfa

2026

Danışman: Prof. Dr. Kazım HANBAY

Sentetik Açıklıklı Radar (SAR) görüntüleri, hava koşullarından ve gün ışığından bağımsız olarak yüksek kaliteli görüntü sağlayabilmeleri nedeniyle denizcilik uygulamalarında yaygın olarak kullanılmaktadır. Ancak SAR görüntülerinde gemi tespiti, koherent benek (speckle) gürültüsü, kıyı bölgelerindeki karmaşık arka plan yapıları ve yoğun hedef dağılımları gibi zorluklar içermektedir. Bu tez kapsamında, düşük kontrastlı, kıyıya yakın ve yoğun hedef içeren SAR görüntülerinde gemi tespitine yönelik hem matematiksel tabanlı hem de derin öğrenme tabanlı yaklaşımlar geliştirilmiştir. Önerilen matematiksel yöntemde, öncelikle kara alanlarının ve benek gürültüsünün etkisini azaltmak amacıyla görüntülerin Hessian matrisi ve özdeğerleri hesaplanmıştır. Elde edilen en büyük özdeğer bilgisi Gauss fonksiyonuna giriş olarak verilmiş, ardından görüntülerin standart sapma ve ortalama haritaları oluşturulmuştur. Bu haritalar olasılıksal bir yaklaşımla birleştirilerek gemi bölgelerini belirginleştiren yeni bir görüntü elde edilmiştir. Son aşamada morfolojik işlemler ve bağlı bileşen analizi uygulanarak gemi adayları tespit edilmiştir. Gerçekleştirilen deneysel çalışmalar, önerilen yöntemin hem doğruluk hem de işlem süresi açısından başarılı sonuçlar verdiğini göstermiştir.

Tez kapsamında önerilen yöntemin dışında ayrıca SAR görüntülerinde gemi tespiti amacıyla YOLO tabanlı derin öğrenme modelleri kullanılmış ve farklı veri kümeleri üzerinde deneysel analizler gerçekleştirilmiştir. Elde edilen sonuçlar, derin öğrenme tabanlı yaklaşımın yüksek tespit performansı sağladığını ortaya koymuştur. Sonuç olarak, hem matematiksel görüntü işleme yöntemleri hem de derin öğrenme tabanlı modeller kullanılarak SAR görüntülerinde gemi tespiti problemine yönelik etkili ve başarılı çözümler geliştirilmiştir.

Anahtar Kelimeler: Görüntü İşleme, Sentetik Açıklıklı Radar, Hessian matrisi.

ABSTRACT

Master Thesis

Ship Detection in SAR Images Using Derivative Based Methods

Hasan Can ÖZBEK

Inonu University

Graduate School of Nature and Applied Sciences

Department of Software Engineering

55+VIII page

2026

Supervisor: Prof. Dr. Kazım HANBAY

Synthetic Aperture Radar (SAR) imagery is widely utilized in maritime applications due to its capability to provide high-quality images regardless of weather and illumination conditions. However, ship detection in SAR images remains a challenging task because of coherent speckle noise, complex coastal backgrounds, and densely distributed targets. In this thesis, both mathematical model-based and deep learning-based approaches are developed for ship detection in low-contrast, inshore, and densely populated SAR scenes. In the proposed mathematical approach, the Hessian matrix and its eigenvalues are first computed to suppress land regions and reduce the effects of speckle noise. The largest eigenvalue is then used as an input to a Gaussian function, and standard deviation and mean maps are generated from the SAR image. These maps are combined using a probabilistic framework to produce an enhanced image that highlights potential ship regions. Finally, morphological operations and connected component analysis are applied to identify ship candidates. Experimental results demonstrate that the proposed method achieves both high detection accuracy and computational efficiency.

In addition, YOLO-based deep learning models are employed for SAR ship detection, and extensive experiments are conducted on different datasets. The obtained results indicate that the deep learning approach provides high detection performance and robust ship localization capabilities. Overall, the findings of this thesis demonstrate that both mathematical image processing techniques and deep learning models can effectively address the SAR ship detection problem and provide accurate and reliable results under challenging imaging conditions.

Keywords: Image Processing, Synthetic Aperture Radar, Hessian matrix.

1. GİRİŞ

Uzaktan algılama ve hedef belirleme teknolojileri günümüzde pek çok disiplin için stratejik öneme sahip hale gelmiştir. Bu kapsamda öne çıkan Sentetik Açıklıklı Radar (SAR) sistemleri, yüksek ayrıntı seviyesinde görüntü üretebilme kabiliyeti ve geniş bölgeleri kapsayabilme avantajı sayesinde özellikle savunma alanında yoğun biçimde kullanılmaktadır. SAR teknolojisinin dikkat çekmesinin temel nedenlerinden biri, ışık koşullarına bağlı kalmaksızın çalışabilmesi ve yağış, bulutluluk ya da sis gibi olumsuz atmosferik şartlarda dahi güvenilir veri üretebilmesidir.

Deniz ulaşımının izlenmesi, çevresel kirliliklerin tespiti, tarım arazilerinin değerlendirilmesi ve kıyı bölgelerinin incelenmesi gibi çok sayıda uygulama alanında SAR görüntülerinden yararlanılmaktadır. Bunun yanı sıra, ülkelerin deniz sınırlarının korunması ve deniz emniyetinin sürdürülebilmesi açısından bu görüntülerin etkin biçimde analiz edilmesi kritik bir rol oynamaktadır. Savunma sanayiinde kullanılan sistemlerde hedeflerin doğru, hızlı ve güvenilir şekilde belirlenmesi amacıyla SAR verilerinin işlenmesi büyük önem taşımaktadır. Yüksek mekânsal çözünürlük sunması, detayları hassas biçimde yansıtabilmesi ve atmosferik engellerden büyük ölçüde bağımsız çalışabilmesi hedef tespit süreçlerini önemli ölçüde kolaylaştırmaktadır. Bu özellikleri sayesinde keşif ve gözetleme faaliyetlerinde, haritalama çalışmalarında ve arazi analizlerinde optik görüntüleme sistemlerine kıyasla farklı ve güçlü avantajlar sağlamaktadır.

SAR tabanlı gemi tespit çalışmaları yalnızca deniz güvenliği açısından değil, aynı zamanda afet durumlarında denizde kaybolan unsurların bulunması ve arama-kurtarma operasyonlarının desteklenmesi bakımından da değer taşımaktadır. Ayrıca, küresel ölçekte giderek artan kaçakçılık faaliyetlerinin ve düzensiz göç hareketlerinin izlenmesinde de etkin bir araç olarak kullanılabilir.

Günümüzde SAR verilerine ulaşmak için çeşitli platformlar ve kaynaklar bulunmaktadır. Açık erişimli uydu programları sayesinde araştırmacılar ücretsiz SAR görüntülerine erişebilmekte ve veri temini konusunda önemli bir kısıt yaşamamaktadır. Literatürde ise farklı problemlere odaklanarak hazırlanmış çok sayıda SAR tabanlı veri seti yer almaktadır. Özellikle gemi tespitine yönelik oluşturulan veri tabanları dikkat çekmektedir. Bu veri setlerinde görüntüler genellikle SAR uydularından elde edilmekte, ardından daha küçük boyutlu parçalara ayrılarak işlenmektedir. Makine öğrenmesi

yöntemlerinin eğitim ve değerlendirme aşamalarında kullanılabilmesi için görüntülerdeki hedef nesneler uygun biçimde etiketlenmektedir. En yaygın kullanılan SAR uyduları ve bu uydulardan veri elde etme süreçlerine ilişkin temel bilgiler aşağıda kısaca sunulmuştur.

1.1 SAR Görüntü Elde Etme

SAR görüntüleri, uzay bilimlerine yönelik araştırmaları yürütmek üzere kurulan Avrupa Uzay Ajansı'nın (ESA) işlettiği, Copernicus Browser olarak adlandırılan platform [1] üzerinden elde edilmektedir. Platformun sunduğu veri seçenekleri arasında sıralanan çeşitli SAR uydularından, incelenen soruna en elverişli kaydı temin edebilecek olanı belirlenerek hedeflenen görseller bilgisayara indirilebilmektedir. Bu kapsamda yürütülen incelemelerde sıklıkla başvurulanan platformların başında Sentinel-1 gelmektedir. Bu tercihin altında yatan başlıca etken, kara izleme ve deniz yüzeyinin gözlemlenmesi gibi uygulamalarda muadil uydulara nazaran daha duyarlı ve tutarlı çıktılar sunabilmesidir. Sentinel takımındaki öteki uydular ağırlıklı olarak atmosfer ve optik temelli ölçümlerde görevlendirilirken, Sentinel-1 ise mikrodalga tabanlı radar tekniği yardımıyla elverişsiz meteorolojik şartlardan bağımsız biçimde yüksek ayrıntı düzeyine sahip görüntüler üretebilmektedir. Sahip olduğu bu özellikler sayesinde Sentinel-1; nesne saptama, arazi izleme ve deniz gözetimi türündeki uygulamalar açısından kullanışlı bir veri sağlayıcısı olarak değerlendirilmektedir.


Sentinel-1 üzerinde konuşlu, C bandında çalışan Sentetik Açıklık Radarı (C-SAR) düzeneği; uçaktan veya uydudan yayılan mikrodalga sinyallerinin zeminden geri yansıması ilkesine dayanarak yüksek ayrıntıda veri elde etmektedir. C-SAR'ın sunduğu ürün düzeyleri arasındaki Level-1 GRD biçimi, barındırdığı radyometrik ve geometrik düzeltmeler nedeniyle mekânsal çözümleme ile harita üretimi aşamalarında işlenebilirliği ve güvenilirliği daha yüksek veriler ortaya koymaktadır. Tarama kipi bakımından, kapsamlı bölgelerin ayrıntılı biçimde görüntülenmesine imkân tanıyan IW (Interferometric Wide Swath) modu yeğlenmektedir. Polarizasyon açısından bakıldığında genellikle VV+VH ikilisi tercih edilmektedir. Bu seçimin gerekçesi, bilhassa deniz yüzeyinin izlenmesi ve denizcilik temelli analizlerde daha nitelikli geri saçılım verisi sunmasından kaynaklanmaktadır.

1.1.1 Gaofen uydusu

Çin'in uzaya dayalı izleme ve keşif programında, Gaofen platformları kayda değer bir rol üstlenmektedir. Çince kökenli "Gaofen" adlandırması, "Yüksek Çözünürlük" karşılığına denk gelmektedir. Söz konusu düzenek, tıpkı Sentinel ailesinde olduğu üzere, ayrıntılı görseller oluşturabilme ve radar temelli izleme gerçekleştirebilme yeteneğini barındırmaktadır. En yaygın görev sahaları içerisinde denizlerin gözetimi, afet takibi ve savunmaya dönük kullanımlar sıralanabilir. Bunlara ek olarak tarımsal faaliyetler, kentsel tasarım ve orman yönetimi gibi konularda da nitelikli çıktılar ortaya koymaktadır. Görüntü oluşturma aşamasında ise ağırlıklı olarak optik temelli bir yöntem benimsenmekte, böylelikle mekânsal ayrıntısı yüksek kayıtların elde edilmesi amaçlanmaktadır.

1.1.2 Sentinel 1

European Space Agency (ESA) tarafından tasarlanıp hizmete sunulan Sentinel-1, bugün çok sayıda inceleme sahasında üstün görüntü niteliği ve ayrıntı düzeyi sunması dolayısıyla değerli bir veri sağlayıcısı konumundadır. Bu uydunun öne çıkan kullanım hedefleri arasında su düzeyinin gözlemlenmesi, tarımsal arazilerin denetlenmesi ve afet/kriz yönetimi sayılabilir. Bunun ötesinde, görüntüleme başarımını her tür meteorolojik durumda sürdürebilmesi nedeniyle savunma sektörü açısından da kritik bir konum edinmiş ve birçok bilimsel araştırmada başvurulacak bir kaynak hâline gelmiştir. Gaofen ile karşılaştırıldığında ise Sentinel-1'i ayıran nokta, çıktılarını Sentetik Açıklıklı Radar (SAR) yöntemiyle oluşturmasıdır.



Şekil 1.1: SAR veri tabanından görüntüler.

1.2 Literatürde Yapılan Çalışmalar

SAR görüntülerinin analizinde görüntü işleme teknikleri, istatistiksel yaklaşımlar ve makine öğrenmesi tabanlı yöntemler yaygın olarak kullanılmaktadır. Bu yöntemler sayesinde görüntülerden anlamlı özniteliklerin elde edilmesi, nesnelerin tespit edilmesi ve izlenmesi ile farklı hedeflerin sınıflandırılması gibi problemlere yönelik etkili çözümler geliştirilebilmektedir. Ayrıca SAR verilerinin uygun ön işleme aşamalarından geçirilerek analiz için hazır hale getirilmesi, kullanılan algoritmaların doğruluk ve performansını önemli ölçüde artırmaktadır. Literatürde, görüntülerde yer alan hedeflerin bölütlenmesi, sınıflandırılması ve gürültü ya da istenmeyen arka plan bileşenlerinin azaltılmasına yönelik çok sayıda çalışma bulunmaktadır. Özellikle gemi ve hava aracı tespiti, sınır gözetleme faaliyetleri, tarımsal alanların izlenmesi ve çevresel değişimlerin analizi gibi uygulama alanlarında SAR görüntülerinden yararlanan önemli araştırmalar gerçekleştirilmiştir. Bir çalışmada, SAR gemi hedef tanıma performansını artırmak amacıyla saçılım merkezlerini derin öğrenme sürecine entegre eden model önerilmiştir. Öncelikle gemi hedefi hassas segmentasyon ile arka plandan ayrılmış, ardından saçılım merkezleri çıkarılarak K-Nearest

Neighboord (KNN) algoritması ile yerel grafik yapılara dönüştürülmüştür. Bu yapılar, SCFA ve MSFE modülleri aracılığıyla ilişkilendirilerek çok ölçekli küresel saçılım özellikleri elde edilmiştir. Özellikle az örnekli durumlarda modelin doğruluk oranını artırdığını göstermiştir [2].

Başka bir çalışmada ise özellikle küçük ve yoğun gemilerin karmaşık liman ve kara arka planlarında tespit edilmesindeki zorlukları gidermek amacıyla NRE-Net (Neighborhood Removal-and-Emphasis Network) adlı bir ağ yapısı önerilmiştir. Yöntemde, özellik çıkarımından önce gemi çevresindeki karmaşık arka plan bilgisini kaldıran Nesne Komşuluk Kaldırma (ONR) stratejisi uygulanarak yalnızca tespit için faydalı bağlamsal bölgeler korunmuştur. Ardından, ONR üzerine inşa edilen Komşuluk Özellik Vurgulama (NFE) modülü ile küçük ölçekli gemiler ve karmaşık sahneler için ağırlık haritaları oluşturularak gemi bölgeleri öne çıkarılmıştır [3].

Fan ve diğerlerinin yaptığı bir çalışmada, uydu tabanlı uzaktan algılama görüntülerinde küçük hedef gemi tespitinde karşılaşılan sınıf dengesizliği ve karmaşık arka plan kaynaklı yanlış/eksik tespit problemlerine odaklanılmıştır. Bu amaçla, farklı karmaşık ortamlarda elde edilmiş 3881 görüntü ve 8418 gemi örneği içeren yeni bir veri seti oluşturulmuştur. Küçük hedef tespit performansını artırmak için CSDP modülünü içeren CSDP-YOLO modeli önerilmiş; bu modülde geniş çekirdekli konvolüsyon ile alıcı alan genişletilmiş ve noktasal konvolüsyon ile kanal-karışımı sağlanarak özellik çıkarımı güçlendirilmiştir. Ayrıca, küçük hedef–arka plan sınıf dengesizliğini azaltmak amacıyla MPDIoU kayıp fonksiyonu modele entegre edilmiştir [4].

Xu vd. yaptığı çalışmada, derin öğrenme tabanlı SAR gemi tespit modellerinin uydu üzerinde doğrudan çalıştırılmasındaki yüksek model karmaşıklığı ve hesaplama maliyeti problemi ele alınmıştır. Bu amaçla YOLOv5 tabanlı, hafifletilmiş bir gemi tespit modeli olan Lite-YOLOv5 önerilmiş; model boyutunu ve FLOPs değerini azaltırken doğruluk performansının korunması hedeflenmiştir. Hafif bir mimari elde etmek için L-CSP modülü tasarlanmış ve ağ budama (network pruning) uygulanmıştır [5].

Yu vd. yaptığı çalışmada, Hebbian sinir ağlarına dayalı aşağıdan-yukarı dikkat (bottom-up attention) modeli önerilmiştir. Modelde, görsel girdinin belirginliği basit bir normalizasyon süreci ile hızlı biçimde hesaplanmakta ve bu belirginlik insan beynindeki nöronal atımları taklit eden ikili kodlar şeklinde temsil edilmektedir. Psikofiziksel desenler ve doğal görüntülerde göz sabitleme tahmini deneyleri, yöntemin etkinliğini ve hesaplama

verimliliğini ortaya koymuştur. Önerilen model ayrıca, gerçek zamanlı olarak büyük veri işlenmesini gerektiren SAR gemi tespit problemine uygulanmıştır. Sonuçlar, modelin benek (speckle) gürültüsüne karşı dayanıklı ve hızlı bir belirginlik tespiti yöntemi sunduğunu göstermiştir [6].

Yu vd. yaptığı çalışmada, kıyı bölgelerdeki çevresel karmaşıklık ve farklı gemi türlerinden kaynaklanan zorlukları ele almak amacıyla YOLOv8 tabanlı YOLO-SRBD (Shuffle Reparameterized Blocks with Dynamic Head) modeli önerilmiştir. Önerilen yöntemde, Shuffle Reparameterized Block yapıları ve dinamik başlık (Dynamic Head) mekanizması kullanılarak özellik çıkarımı ve çok ölçekli temsil yeteneği güçlendirilmiştir. Ayrıca, tespit hassasiyetini artırmak amacıyla son işlem aşamasında Soft-NMS uygulanmıştır. SAR görüntü veri setleri üzerinde gerçekleştirilen deneyler, modelin hem nitel hem nicel olarak temel YOLOv8 mimarisini geride bıraktığını göstermiştir. Yüksek çözünürlüklü SAR veri setinde doğruluk oranının %89,9'dan %91,3'e, ortalama hassasiyetin ise %66,7'den %74,3'e yükselmesi yöntemin performans artışı ortaya koymuştur [7].

Wei vd. yaptığı çalışmada, yüksek çözünürlüklü SAR görüntülerinde gemi tespiti ve örnek (instance) segmentasyon çalışmalarını desteklemek amacıyla High-Resolution SAR Images Dataset (HRSID) veri seti oluşturulmuştur. Mevcut SAR veri setlerindeki sınırlı örnek sayısı, küçük görüntü boyutları ve hatalı etiketleme problemlerinin araştırmaları kısıtladığı belirtilmiştir. Bu kapsamda, 1–5 m çözünürlüğe sahip 136 panoramik SAR görüntüsü %25 örtüşme oranı ile 800×800 piksel boyutunda kesilerek toplam 5604 görüntü ve 16951 gemi örneği içeren veri seti hazırlanmıştır. Yanlış ve eksik etiketlemeyi azaltmak amacıyla optik uzaktan algılama görüntülerinden de yararlanılmış; veri seti %65 eğitim ve %35 test olacak şekilde MS COCO formatında düzenlenmiştir. Sekiz güncel tespit algoritması ile yapılan deneyler, HRSID'in hem gemi tespiti hem de örnek segmentasyon görevleri için uygun ve kapsamlı bir temel oluşturduğunu göstermiştir [8].

Zhang vd. yaptığı çalışmada, derin öğrenme tabanlı SAR gemi tespitinde yaygın olarak kullanılan SSDD veri setinin ilk sürümündeki kaba etiketleme ve belirsiz kullanım standartlarının adil karşılaştırmaları zorlaştırdığı belirtilmiştir. Bu sorunları gidermek amacıyla SSDD'nin resmi ve geliştirilmiş bir sürümü yayımlanmış; yatay-dikey sınırlayıcı kutu (BBox), döndürülebilir sınırlayıcı kutu (RBox) ve piksel seviyesinde çokgen segmentasyon (PSeg) olmak üzere üç farklı etiketleme türü sunulmuştur. Veri setindeki gemiler daha hassas biçimde yeniden etiketlenmiş ve eğitim-test ayrımı, kıyı-açık deniz protokolü ve küçük/yoğun gemi tanımları gibi net kullanım standartları belirlenmiştir.

Ayrıca, üç sürüm üzerinde kapsamlı veri analizi gerçekleştirilerek gelecekte daha doğru ve dayanıklı SAR gemi tespit modellerinin geliştirilmesine yönelik öneriler sunulmuştur [9].

Cui vd. yaptığı çalışmada, SAR görüntülerinde farklı ölçeklerdeki gemilerin, özellikle küçük ölçekli hedeflerin tespitindeki zorluklar ele alınmıştır. Bu amaçla, yoğun dikkat piramit ağına (Dense Attention Pyramid Network - DAPN) dayalı çok ölçekli bir gemi tespit yöntemi önerilmiştir. Önerilen yapıda, piramit mimarisi boyunca her birleştirilmiş özellik haritasına CBAM (Convolutional Block Attention Module) entegre edilerek hem çözünürlük hem de semantik bilgi içeren zengin özellikler çıkarılmış ve ölçeğe özgü belirgin bölgeler vurgulanmıştır. Elde edilen dikkat temelli özellikler, küresel ve bulanıklaştırılmamış özelliklerle birleştirilerek tespit doğruluğu artırılmıştır. SSDD [10] veri seti üzerinde yapılan deneyler, yöntemin farklı sahnelerdeki çok ölçekli gemileri yüksek doğrulukla tespit ettiğini ve mevcut yöntemlere üstünlük sağladığını göstermiştir [11].

Jiamei Fu vd. yaptığı çalışmada, farklı ölçeklerdeki SAR gemilerinin ve özellikle kıyı bölgelerindeki karmaşık arka planın neden olduğu tespit zorluklarını ele almak amacıyla Feature Balancing and Refinement Network (FBR-Net) önerilmiştir. Çalışmada, önceden tanımlı anchor kutularına bağımlılığı ortadan kaldırmak için anchor-free bir strateji benimsenmiş ve sınırlayıcı kutular doğrudan öğrenilmiştir. Ayrıca, dikkat güdümlü dengeli piramit yapısı ile farklı seviyelerdeki özelliklerin semantik olarak dengelenmesi sağlanarak küçük ölçekli gemilerin temsil gücü artırılmıştır. Konumlandırma hatalarını azaltmak amacıyla özellik iyileştirme (feature-refinement) modülü geliştirilmiş ve gemi sınır bölgelerindeki saçılım benzerliğinden kaynaklanan hizalama problemleri giderilmeye çalışılmıştır. Çalışma, önerilen yöntemin güncel anchor-free yaklaşımlara kıyasla daha üstün performans elde ettiğini göstermiştir [12].

Yujun Zhang vd. yaptığı çalışmada, SAR görüntülerinde güçlü saçılım, belirsiz kenar yapıları ve arka plan karmaşıklığından kaynaklanan düşük tespit doğruluğu problemini ele almak amacıyla Swin-PAFF adlı çok ölçekli füzyon çerçevesi önerilmiştir. Yöntemde, küresel bağlam algılama yeteneğinden yararlanmak için Transformer tabanlı bir omurga kullanılmış ve Swin Transformer yapısı SDP modülü ile güçlendirilerek bağlamsal özellik çıkarımı artırılmıştır. Çok katmanlı özellik birleşimini sağlamak amacıyla çapraz katmanlı füzyon modülü (PAFF) tasarlanarak çok ölçekli ve karmaşık sahnelerde daha etkin temsil elde edilmiştir [13].

Joseph Redmon vd. yaptığı çalışmada, nesne tespiti problemi sınıflandırma temelli yaklaşımlar yerine regresyon problemi olarak ele alınmış ve YOLO modeli önerilmiştir. Bu yaklaşımda, tek bir sinir ağı tam görüntü üzerinden doğrudan sınırlayıcı kutuları ve sınıf olasılıklarını uçtan uca (end-to-end) biçimde tahmin etmektedir. Model, gerçek zamanlı çalışabilecek hızda tasarlanmış olup temel sürümü saniyede 45 kare, Fast YOLO versiyonu ise 155 kare işleyebilmektedir. YOLO'nun konumlandırma hataları diğer yöntemlere göre nispeten fazla olsa da arka plan üzerinde yanlış pozitif üretme oranı daha düşüktür [14].

Shaoqing Ren vd. yaptığı çalışmada, bölge öneri algoritmalarının nesne tespit ağlarında darboğaz oluşturması problemini ele alarak Region Proposal Network (RPN) yapısını önermiştir. RPN, tespit ağı ile aynı evrimsel özellik haritalarını paylaşarak ek maliyet oluşturmada nesne aday bölgeleri üretmekte ve her konum için hem sınırlayıcı kutu hem de nesne olasılığı tahmini yapmaktadır. Bu yapı, Fast R-CNN ile bütünleştirilerek tek bir uçtan uca eğitilebilen ağ hâline getirilmiş ve böylece Faster R-CNN mimarisi oluşturulmuştur [15].

Girshick yaptığı çalışmada, nesne tespiti için Fast R-CNN yöntemini önermiştir. Bu yaklaşım, bölge önerilerini derin evrimsel sinir ağları ile daha verimli biçimde sınıflandırarak önceki R-CNN tabanlı yöntemlere göre hem eğitim hem de test süresini önemli ölçüde azaltmıştır. Özellikle VGG-16 ağı ile R-CNN'e kıyasla 9 kat daha hızlı eğitim ve 213 kat daha hızlı test süresi sağlarken, PASCAL VOC 2012 üzerinde daha yüksek mAP değeri elde etmiştir. Ayrıca SPPnet ile karşılaştırıldığında da hem hız hem doğruluk açısından üstünlük göstermiştir. Yöntem, Caffe altyapısı kullanılarak Python ve C++ ortamında açık kaynak olarak yayımlanmıştır [16].

Kaiming He vd. yaptığı çalışmada, nesne örnek segmentasyonu için basit ve genel bir çerçeve olan Mask R-CNN modelini önermiştir. Bu yöntem, Faster R-CNN mimarisini genişleterek sınırlayıcı kutu tahminine paralel olarak her nesne için piksel düzeyinde maske üreten ek bir dal eklemektedir. Model, düşük ek hesaplama maliyetiyle yaklaşık 5 fps hızında çalışabilmekte ve insan pozu tahmini gibi farklı görevlere de kolayca uyarlanabilmektedir. MS COCO yarışmalarında örnek segmentasyon, nesne tespiti ve anahtar nokta tespiti görevlerinde en yüksek performans sonuçlarını elde etmiştir. Mask R-CNN, ek iyileştirme hilelerine ihtiyaç duymadan önceki tekil modellere kıyasla üstün başarı göstererek örnek seviyesinde tanıma çalışmaları için güçlü bir temel sunmuştur [17].

Özdemir tarafından gerçekleştirilen tez çalışmasında, SAR görüntülerinde gemilerin tespit edilmesi ve sınıflandırılması amacıyla iki farklı yöntem geliştirilmiş ve bu kapsamda dünyanın çeşitli liman, deniz ve okyanuslarından elde edilen görüntülerden oluşan kapsamlı bir SAR gemi görüntüsü veri tabanı oluşturulmuştur. Birinci yöntemde, gri seviye eş-oluşum matrisinden (GLCM) dört farklı istatistiksel ölçüm aracılığıyla öznitelik vektörleri çıkarılmış; matrisin oluşturulmasında Gauss türev filtreleri kullanılmış ve elde edilen öznitelikler destek vektör makineleri (SVM) ile sınıflandırılmıştır. İkinci yöntemde ise görüntülerin Hessian matrisleri ve bu matrise ait özdeğerler hesaplanarak gradyan büyüklüğü ve yönelimleri elde edilmiş, bu bilgiler yardımıyla yapılan histogram etiketleme ile gemi ve gemi-dışı bölgeler ayırt edilerek öznitelik vektörleri yapay sinir ağları ile sınıflandırılmıştır. Yerel İkili Örüntü (LBP) yöntemiyle karşılaştırılan önerilen yaklaşımların, deneysel sonuçlara göre gemi sınıflandırmasında etkili sonuçlar sağladığı görülmüştür [18].

Leng vd. yaptığı çalışmada, SAR görüntülerinde gemi tespiti için çift taraflı sabit yanlış alarm oranı algoritması (Bilateral CFAR) önerilmiştir. Standart CFAR yönteminden farklı olarak, yoğunluk dağılımı ile birlikte mekânsal dağılım bilgisini birleştirerek SAR belirsizlikleri ve deniz karmaşasının etkisini azaltmayı amaçlamıştır. Mekânsal dağılım, gemi tespitinden önce önerilen yeni bir çekirdek yoğunluk kestirim (kernel density estimation) yöntemi ile hesaplanmıştır. Bu yaklaşımda, mekânsal bilginin yoğunluk bilgisi kadar önemli olduğu vurgulanmıştır. Deneysel sonuçlar, önerilen yöntemin tipik SAR görüntülerinde etkili tespit performansı sağladığını göstermiştir [19].

Xie vd. yaptığı çalışmada, SAR görüntülerinde gemi tespitinde kullanılan klasik CFAR ve bilgi geometrisi temelli yöntemlerin karmaşık deniz sahnelerinde sınırlı performans göstermesi problemi ele alınmıştır. Bu kapsamda, deniz karmaşasının dağılım modelini varsaymadan çalışan, örnek kovaryans matrisinin maksimum özdeğerine dayalı yeni bir gemi tespit algoritması önerilmiştir. Yöntemde, hedef ile arka plan arasındaki fark örnek kovaryans matrisi üzerinden temsil edilmiş ve maksimum özdeğer test istatistiği olarak kullanılmıştır. Böylece dağılım modellemesine ihtiyaç duyulmadan hedef–arka plan ayrımı gerçekleştirilmiştir. Gerçek SAR görüntüleri üzerinde yapılan deneyler, önerilen yöntemin mevcut tipik yaklaşımlara kıyasla hem daha yüksek tespit performansı hem de daha hızlı hesaplama süresi sağladığını göstermiştir [20].

Erçelik vd. yaptığı çalışmada, SAR görüntülerinde gemi tespiti; karmaşık arka plan yapıları, düşük kontrast ve benek (speckle) gürültüsü nedeniyle önemli bir araştırma problemi olduğu vurgulanmış ve hem küçük hem de büyük gemilerin doğru biçimde tespit edilebilmesi amacıyla CLAHE (Kontrast Sınırlı Uyarlamalı Histogram Eşitleme) tabanlı ön işleme ile YOLOv8x derin öğrenme mimarisini birleştiren bir nesne tespit sistemi önerilmiştir. CLAHE algoritması, görüntülerdeki yerel kontrastı artırıp gürültü ve bozulmaları azaltarak ağın daha etkin öğrenmesine olanak sağlamaktadır. Yüksek çözünürlüklü Sentinel-1 SAR görüntülerinden oluşturulan özgün bir veri kümesi üzerinde gerçekleştirilen deneyler, önerilen modelin hem YOLOv8x hem de YOLOv8n modellerini geride bıraktığını ortaya koymuştur [21].

Hanbay vd. yaptığı çalışmada, SAR görüntülerinden gemi tespiti yapabilmek amacıyla bir görüntü veri tabanı oluşturulmuştur. Görüntüler literatüre uygun şekilde ön işleme tabi tutularak gemi tespit yöntemleri için uygun hale getirilmiş ve derin öğrenme tabanlı bir mimari ile görüntülerdeki gürültü azaltılmıştır. Oluşturulan bu veri tabanı kullanılarak, görüntü işleme ve makine öğrenmesi yöntemleriyle gemi tespit yöntemleri geliştirilmiştir. Bu tez çalışması kapsamında ilgili veritabanına yeni görüntüler eklenmiş ve kapsamı genişletilmiştir [22].

Hanbay'ın yaptığı diğer bir çalışmada ise, SAR görüntülerinde özellikle benek (speckle) gürültüsünden kaynaklanan yüksek yanlış alarm oranlarını azaltmak ve düşük kontrastlı, kıyıya yakın ve yoğun hedeflerde gemileri doğru biçimde tespit edebilmek amacıyla verimli bir gemi tespit yöntemi önerilmiştir. Bu kapsamda öncelikle kara alanlarının ve gürültünün ayıklanması için görüntülerin Hessian matrisi ve özdeğerleri hesaplanmış; elde edilen en büyük özdeğer bilgisi bir Gauss fonksiyonuna girdi olarak verilerek görüntülere ait standart sapma ve ortalama görüntüleri üretilmiştir. Ardından bu standart sapma ve ortalama görüntüleri olasılıksal bir yaklaşımla birleştirilerek gemi bölgelerini öne çıkaran bir görüntü elde edilmiş, bu görüntü üzerinde morfolojik işlemler ve bağlı bileşen analizi uygulanmıştır. Deneysel sonuçlar, önerilen yöntemin hem daha doğru hem de daha hızlı sonuçlar sağladığını ortaya koymuştur [23].


1.3 Tezin Amacı

Bu tez çalışmasının temel amacı SAR görüntülerinde görüntü işleme ile matematiksel yöntemlerden yararlanarak gemilerin belirlenmesini sağlayan yöntemler geliştirmektir. Günümüzde gemilerin hızlı ve güvenilir biçimde tespit edilmesi; deniz güvenliğinin artırılması, sınırların izlenmesi, keşif ve gözetleme faaliyetlerinin etkin yürütülmesi, liman operasyonlarının düzenlenmesi ve deniz trafiğinin kontrol altında tutulması açısından büyük önem taşımaktadır. Ayrıca deniz yüzeyindeki kirlilik ve atıkların belirlenerek gerekli müdahalelerin yapılabilmesi için de gemi tespit sistemlerine ihtiyaç duyulmaktadır. Bu kapsamda gerçekleştirilen çalışmada, SAR görüntülerinde yer alan gemiler; kıyı bölgeleri ve gemi dışındaki nesnelerden ayırt edilerek başarılı bir şekilde sınıflandırılmıştır. Gauss fonksiyonu, hessian matrisi ve öz değerler kullanılarak matematiksel temelli bir yöntem geliştirilmiştir. Ayrıca YOLO modeli ile de kapsamlı testler yapılmıştır. Kullanılan yöntemler doğruluk, hassasiyet, duyarlılık ve F1 skor parametreleri ile test edilmiştir.

2. YENİ SAR GEMİ VERİ TABANI

Bu bölümde, literatürde yaygın olarak kullanılan SAR tabanlı gemi veri kümeleri hakkında genel bilgiler sunulmuştur. Ardından tez kapsamında geliştirilen yeni SAR gemi veri tabanının oluşturulma süreci ayrıntılı olarak açıklanmıştır. Veri tabanının oluşturulması iki temel aşamadan meydana gelmektedir. İlk aşamada, belirlenen parametreler doğrultusunda uydu görüntüleri temin edilerek gemilere ait SAR verileri elde edilmiştir. İkinci aşamada ise elde edilen görüntüler kullanılacak modellerin gereksinimlerine uygun formatlara dönüştürülmüş ve çeşitli görüntü işleme teknikleri uygulanarak görüntü kalitesi artırılmıştır. Böylece gemi hedeflerinin daha belirgin hale getirildiği ve analiz süreçlerine uygun bir veri tabanı oluşturulmuştur.

Mevcut literatürde SAR görüntüleri ile gemi tespitine yönelik sınırlı sayıda açık kaynak veri tabanı bulunmaktadır. Bu başlıkta literatürde en çok kullanılan veri tabanları hakkında kısa bilgilere yer verilecektir. Şekil 2.1.'de mevcut veri tabanlarından örnek görüntüler verilmiştir.



Şekil 2.1: Literatürdeki bazı SAR veri setlerinden görüntüler.

SAR-Ship-Dataset veri kümesindeki kayıtlar, 256×256 piksellik bloklara bölünmüştür. Bu kümede, küçük boyutlu 43.819 ve büyük boyutlu 59.535 gemi görüntüsü bulunmaktadır. İlgili görüntüler; 25 m, 10 m, 8 m, 5 m ve 3 m biçiminde sıralanabilen muhtelif mekânsal ayrıntı düzeylerine sahip olup tam (full), çift ve tek polarizasyon kipleriyle üretilmiştir. Daha önceki incelemelerde benimsenen tutuma koşut biçimde, mevcut çalışmada da radar görüntülerinin isabetini güvence altına almak amacıyla bu konuda yetkin SAR analistlerinin katkısına başvurulmuştur. Harici bir denetim kaynağı niteliğindeki AIS ya da Google Earth devreye alınmadığından, kayıtların işaretlenme (annotation) aşaması bütünüyle SAR uzmanlarının birikimine ve deneyimine yaslanılarak yürütülmüştür [24].

IR-SARShip-v1.0 veri kümesi, Gaofen-3 platformu yardımıyla muhtelif coğrafyalardan ve birbirinden ayrılan ortam koşullarında (engin deniz yüzeyi, liman çevreleri, ada kıyıları vb.) toplanmış 31 SAR görüntüsünü barındırmaktadır. Bu kayıtların her biri 3000×3000 piksel ölçeğindedir. Kümeyi oluşturan görüntüler, 1 m ile 3 m aralığında mekânsal ayrıntıya ve VV (dikey) polarizasyona sahiptir. İşlenmemiş SAR kayıtları 500×500 piksellik alt bölümlere ayrıştırılarak eğitim ve sınamaya kümeleri meydana getirilmiştir. İşaretleme aşamasında Google Earth ile AIS kayıtlarından yararlanılmamış, bunun yerine geçerlilik denetimi dolaysız biçimde SAR uzmanlarının görüşlerine dayandırılmıştır.

HRSID veri kümesi; Sentinel-1 ile TerraSAR-X platformlarından, birbirinden ayrı polarizasyon kiplerinde (yatay, dikey ile çapraz/yönlendirilmiş türleri kapsayacak biçimde) toplanan 5604 işlenmemiş SAR görüntüsünü içermektedir. İlgili kayıtların mekânsal ayrıntı düzeyleri 3 m, 1 m ve 0.5 m olarak verilmiştir. Ham veriler 800×800 piksellik parçalara bölünmüş, bu işlemin sonucunda 16.951 gemi örneğine ulaşılmıştır. Kümedeki gemi işaretleri hazırlanırken Google Earth yardımıyla gözle kontrol gerçekleştirilmiştir [25].

LS-SSDD-v1.0 veri kümesi, Sentinel-1 platformundan dikey polarizasyon kipiyle elde edilen, 24.000×16.000 piksel ölçeğindeki 15 işlenmemiş SAR görüntüsünü içine almaktadır. Geniş ölçekli her bir kayıt 800×800 piksellik alt görüntülere bölünmüş ve toplamda 6015 gemi örneği ortaya çıkarılmıştır. Doğrulama aşamasında AIS ile Google Earth verilerinden yararlanılarak geçerlilik kontrolü tamamlanmıştır [26].

SSDD veri kümesi ise Sentinel-1, TerraSAR-X ve RadarSat-1 platformlarından; VV (dikey), HH (yatay), yatay-yatay ile dikey-dikey polarizasyon kiplerinde derlenmiş, 500×500 piksel ölçeğindeki 1160 işlenmemiş SAR görüntüsünden oluşmaktadır. Bu kümede toplam 2358 gemi nesnesi yer almakta olup kayıtların mekânsal ayrıntısı 1 m ile 15 m bandında değişiklik göstermektedir. Gemilerin işaretlenmesi sırasında AIS veya Google Earth türündeki yardımcı kaynaklara başvurulmamış, doğrulamaların tümü SAR uzmanlarınca yürütülmüştür [27].

SRSDD-v1.0 veri kümesi, gemileri altı ayrı alt sınıf çerçevesinde gruplandırmaktadır. Bu küme, Gaofen-3 platformundan toplanmış 30 geniş açılı SAR görüntüsünü kapsamaktadır. Anılan kayıtların mekânsal ayrıntısı 1 m düzeyinde saptanmıştır. İşlenmemiş görüntüler 1024×1024 piksellik alt bölümlere ayrılmıştır. Bunun yanı sıra kümedeki kayıtların önemli bir kısmı, karışık arka plan dokusuna sahip ve kıyı hattına komşu alanları içeren görünümlerden meydana gelmektedir [28].

SAR Gemi Tespiti Veri Kümelerinin Karşılaştırması

Veri Seti	Tarih	Kaynak	Çözünürlük	Görüntü Boyutu	Görüntü / Gemi	Anotasyon Teknikleri	Notlar / Öne Çıkan Özellik
SSDD	01/12/2017	RadarSat-2, TerraSAR, Sentinel-1	1 m, 15 m	190×888	1160 / 2456	Dikey Yönlendirilmiş	Halka açık ilk SAR gemi tespiti veri kümesi, en yaygın kıyaslama ölçütü.
SAR-Ship-Dataset	29/03/2019	Gaofen-3, Sentinel-1	3 m, 25 m	256×256	43.918 / 59.535	Dikey	Çok sayıda 256×256 yamadan oluşan büyük ölçekli eğitim seti.
AIR-SARShip-1.0	01/12/2019	Gaofen-3	1 m, 3 m	3000×3000	31	Dikey	Az sayıda fakat büyük ve yüksek çözünürlüklü Gaofen-3 sahnesi içerir.
LS-SSDD-v1.0	15/09/2020	Sentinel-1	5 m, 20 m	24000×16000	15 / 6015	Dikey	Büyük sahnelerde küçük gemi tespitine odaklanır; geniş arka plan bağlantı.
HRSID	29/06/2020	Sentinel-1, TerraSAR	0.5 m, 1 m, 3 m	800×800	5604 / 16.851	Yönlendirilmiş	Yüksek çözünürlüklü; tespitin yanı sıra örnek bazlı segmentasyonu da destekler.
SRSDD-V1.0	15/08/2021	Gaofen-3, Sentinel-1	1 m, 10 m	256×256	25.000 / 35.000	Dikey Yönlendirilmiş	Döndürülmüş kutu anotasyonlu, çok sınıflı gemi veri kümesi.

Çizelge 2.1: Literatürdeki Gemi Veritabanları

2.1 Üretilen SAR Gemi Veri Tabanı

Tez çalışmasında gerek duyulan verilerin elde edilmesinde, uzay araştırmaları ve uzay teknolojileri alanında çalışmalar yürüten Avrupa Uzay Ajansı (European Space Agency, ESA) bünyesinde hayata geçirilen Copernicus Programı temel veri kaynağı olarak benimsenmiştir. Çevresel sürdürülebilirlik ve güvenlik önceliklerini gözetken bu program kapsamında, yüksek çözünürlüklü uydu gözlem verilerinin kullanıcılara açıldığı Copernicus Browser platformu tercih edilmiştir. Söz konusu platform, Dünya gözlem (Earth Observation) faaliyetleri çerçevesinde gezegen yüzeyindeki çevresel değişimlerin izlenmesi,

sürekli olarak takip edilmesi ve analiz edilmesi amacıyla geliştirilmiş, web tabanlı bir veri erişim ve sorgulama sistemidir. Platformun en belirgin özelliklerinden biri, program kapsamında üretilen uydu verilerine herhangi bir ücret talep etmeksizin serbest erişim sağlamasıdır; bu durum, akademik çalışmalar açısından önemli bir kolaylık sunmaktadır. İçerdiği veri kaynakları bakımından platform, Sentinel uydu ailesinin farklı üyelerine (Sentinel-1, Sentinel-2, Sentinel-3, Sentinel-5P ve Sentinel-6) ve bunların yanı sıra CCM Optical veri setlerine erişim imkânı tanımaktadır.

Sentinel Uydu Ailesi ve Temel Özellikleri

Uydu	Veri Türü	Kullanım Alanları	Özellikleri
Sentinel-1	Radar Görüntüleme (SAR)	Tarım, ormancılık, toprak hareketleri, deniz güvenliği, acil durum yönetimi	Yüksek çözünürlük; her türlü hava koşulunda görüntü sağlama
Sentinel-2	Optik Görüntü	Tarım, ormancılık, su kaynakları, doğal afetler	Yüksek çözünürlüklü multispektral görüntüler; bitki örtüsü, toprak ve su izleme
Sentinel-3	Deniz ve Kara Gözlemleri	Deniz yüzeyi sıcaklıkları, okyanus ve kara yüzeyi yükseklikleri, biyolojik üretkenlik, iklim	Sunulan yüzeylerin yüksekliklerini yüksek doğruluk oranıyla sağlama
Sentinel-5P	Atmosferik İzleme	Hava kirliliği, ozon tabakası, gaz emisyonları ve hava kalitesi	Atmosferdeki gazların dağılımını belirleme
Sentinel-6	Deniz Yüzeyi Yüksekliği	Deniz seviyesi değişiklikleri, okyanus sirkülasyonu, iklim değişikliği	Yüksek doğrulukla deniz yüzeyi yüksekliklerini sağlama
CCM Optical	Optik Görüntüleme	Çeşitli çevresel ve arazi gözlemleri	Yüksek çözünürlüklü optik görüntüler

Çizelge 2.2: Uydu verilerinin kullanım alanları ve özellikleri

Bu uydu sistemlerinin her biri farklı bir gözlem amacına ve teknik kabiliyete sahiptir. Sentinel-1, radar görüntüleme (SAR) tekniğini esas alan bir sistem olup tarım, ormancılık, toprak hareketlerinin gözlemlenmesi, deniz güvenliği ve acil durum yönetimi gibi alanlarda yaygın biçimde kullanılmaktadır; en ayırt edici niteliği, yüksek çözünürlük sunmasının yanı sıra her türlü hava koşulunda görüntü üretebilmesidir. Sentinel-2 ise optik görüntüleme prensibiyle çalışmakta; tarım, ormancılık, su kaynaklarının yönetimi ve doğal afetlerin değerlendirilmesi gibi uygulamalarda öne çıkmaktadır. Bu uydu, yüksek çözünürlüklü multispektral görüntüler aracılığıyla bitki örtüsünün, toprağın ve su kütlelerinin izlenmesine olanak tanır. Sentinel-3, deniz ve kara gözlemlerine odaklanan bir platform olarak deniz yüzeyi sıcaklıklarının, okyanus ve kara yüzeyi yüksekliklerinin, biyolojik üretkenliğin ve iklimsel parametrelerin ölçülmesinde kullanılmakta; gözlemlenen yüzeylerin yükseklik değerlerini yüksek bir doğruluk oranıyla sağlamaktadır. Atmosferik izlemeye yönelik tasarlanan Sentinel-5P, hava kirliliği, ozon tabakası, gaz emisyonları ve hava kalitesi gibi konularda veri üretmekte ve atmosferdeki gazların dağılımını ortaya koymaktadır. Deniz yüzeyi yüksekliğinin belirlenmesine adanmış olan Sentinel-6, deniz seviyesindeki değişimlerin, okyanus sirkülasyonunun ve iklim değişikliğine bağlı eğilimlerin izlenmesinde rol oynamakta ve deniz yüzeyi yüksekliklerini yüksek doğrulukla raporlamaktadır. Son

olarak CCM Optical, optik görüntüleme yeteneğiyle çeşitli çevresel ve arazi temelli gözlemlerde kullanılmakta ve yüksek çözünürlüklü optik görüntüler sunmaktadır. Bu çeşitlilik, Copernicus ekosisteminin birbirinden farklı uygulama alanlarına hitap eden kapsamlı bir gözlem altyapısı sunduğunu açıkça göstermektedir.

Bu çalışmada, anılan veri kaynakları arasından özellikle Sentinel-1 uydusuna ait işlenmemiş (ham) SAR görüntülerinden yararlanılmıştır. Sentinel-1'in tercih edilmesinde rol oynayan başlıca etkenler; geniş coğrafi alanları tek seferde tarayabilme kapasitesi, sunduğu yüksek mekânsal çözünürlük sayesinde küçük ölçekli nesnelerin dahi tespit edilebilmesine olanak vermesi ve kısa yörünge tekrar süresi (revisit time) sayesinde belirli bölgelerin düzenli aralıklarla yeniden görüntülenebilmesidir. Bu nitelikler bir arada değerlendirildiğinde, gemi hareketlerinin ve genel deniz trafiğinin güncel ve süreklilik arz eden bir biçimde izlenmesine zemin hazırlamaktadır. Bunlara ek olarak, sistemin radar tabanlı bir görüntüleme prensibine dayanması; bulutluluk, yağış veya sis gibi olumsuz hava koşullarından bağımsız olarak ve gece ile gündüz ayrımı gözetmeksizin kesintisiz görüntü elde edilebilmesini sağlamaktadır. Bu özellik, optik sistemlerin aydınlatma ve atmosferik koşullara olan bağımlılığı düşünüldüğünde, deniz gözetimi gibi süreklilik gerektiren uygulamalar açısından kritik bir üstünlük oluşturmaktadır.

Copernicus Browser arayüzünde Sentinel-1 uydusu seçildikten sonra, ağırlıklı olarak kara ve deniz yüzeylerinin gözlemlenmesinde kullanılan C-SAR (C-band Synthetic Aperture Radar) radar sistemi tercih edilmiştir. C-SAR kapsamında sunulan alt ürün seçenekleri içerisinde, coğrafi referanslama (georeferencing) bilgisi içeren ve elde edilen görüntülerin harita üzerinde doğru biçimde konumlandırılmasına imkân tanıyan Level-1 GRD (Ground Range Detected) veri işleme seviyesi benimsenmiştir. Edinim modunun (Acquisition Mode) belirlenmesi aşamasında, Sentinel-1 sisteminin sunduğu farklı çalışma modlarının özellikleri göz önünde bulundurulmuştur. Bu modlardan ilki olan SM (Strip Map Mode), dar coğrafi alanlar üzerinde yaklaşık 5 m (Ground Range) çözünürlükte yüksek detaylı görüntüler üretmek amacıyla kullanılmaktadır. IW (Interferometric Wide Swath) modu ise geniş alanların görüntülenmesine ve interferometrik analizlerin gerçekleştirilmesine olanak tanımakta olup, menzil ve azimut yönlerinde yaklaşık 5 m × 20 m (Range × Azimuth) çözünürlük sunmaktadır. EW (Extra Wide Swath) modu, çok daha geniş alanların kapsanmasını sağlamakta; ancak bunu görece düşük bir çözünürlük (yaklaşık 20 m, Ground Range) karşılığında gerçekleştirmektedir. WW (Wave Mode) ise deniz dalgaları ve okyanus yüzeyindeki hareketler gibi dinamik su kütlelerinin izlenmesine yönelik olarak yaklaşık 5 m

(Ground Range) çözünürlükte çalışmaktadır. Tüm bu seçenekler arasından; geniş alan kapsama kabiliyeti, çoklu polarizasyon desteğine olanak vermesi, zorlu hava koşullarına karşı dayanıklılığı, interferometrik analiz yapabilme kapasitesi ve yüzeydeki değişimleri etkili biçimde izleyebilme avantajları nedeniyle IW modu bu çalışma için en uygun seçenek olarak değerlendirilmiş ve tercih edilmiştir. Söz konusu modun, geniş tarama genişliği ile makul düzeydeki çözünürlük arasında kurduğu denge, geniş deniz alanlarında gemi tespiti yapılması hedefiyle de doğrudan örtüşmektedir.

Polarizasyon yapılandırmasında ise VV+VH kombinasyonu kullanılmıştır. SAR sistemlerinde polarizasyon, radar dalgasının gönderilmesi ve geri alınması sırasındaki yönelimini ifade etmekte olup farklı yapılandırmalar yüzey ile nesne etkileşimleri hakkında birbirinden farklı bilgiler sunmaktadır. Bu yapılandırmalardan HH (Horizontal transmit, Horizontal receive), radar dalgalarının yatay polarizasyonda gönderilip yine yatay polarizasyonda alınmasını; VV (Vertical transmit, Vertical receive) ise dalgaların dikey polarizasyonda gönderilip dikey polarizasyonda alınmasını tanımlamaktadır. Çift polarizasyonlu yapılandırmalardan VV+VH (Vertical transmit, Vertical and Horizontal receive), radar sinyalinin dikey polarizasyonda gönderilip hem dikey hem de yatay polarizasyonda alınmasını; HH+HV (Horizontal transmit, Horizontal and Vertical receive) ise sinyalin yatay polarizasyonda gönderilip hem dikey hem de yatay polarizasyonda alınmasını ifade etmektedir. Bu çalışmada benimsenen VV+VH kombinasyonunda VV polarizasyonu, deniz yüzeyi ve dalgalar gibi nispeten yatay sayılabilecek yüzeylerden güçlü bir geri saçılım (backscatter) üretirken; VH polarizasyonu daha karmaşık yüzey ve nesne etkileşimlerinin yakalanmasına olanak tanımaktadır. Bu iki polarizasyon türünün bir arada değerlendirilmesi, yüzey özelliklerinin daha ayrıntılı bir biçimde çözümlenmesini ve gemi benzeri nesnelerin arka plandan daha güvenilir biçimde ayrıştırılmasını mümkün kılmaktadır. Özellikle VH polarizasyonunun, deniz yüzeyindeki geri saçılım kaynaklı

beneklenmeyi (speckle noise) görece azaltarak hedef nesnelerin arka plana kıyasla daha belirgin hâle gelmesine katkı sağladığı gözlemlenmiştir.

Polarizasyon Türleri

Polarizasyon Türü	Açıklama
HH Horizontal transmit, Horizontal receive	Radar dalgalarının yatay polarizasyonda gönderilip yatay polarizasyonda alınması.
VV Vertical transmit, Vertical receive	Radar dalgalarının dikey polarizasyonda gönderilip dikey polarizasyonda alınması.
VV+VH Vertical transmit, Vertical and Horizontal receive	Radar dalgalarının dikey polarizasyonda gönderilip hem dikey hem de yatay polarizasyonda alınması.
HH+HV Horizontal transmit, Horizontal and Vertical receive	Radar dalgalarının yatay polarizasyonda gönderilip hem dikey hem de yatay polarizasyonda alınması.

Edinim Modları (Acquisition Modes)

Mod	Açıklama	Çözünürlük
SM Strip Map Mode	Dar alanlarda yüksek çözünürlüklü görüntüler sağlar.	5 m (Ground Range)
IW Interferometric Wide Swath	Geniş alanları görüntüler ve interferometrik analizler için kullanılır.	5 m × 20 m (Range × Azimuth)
EW Extra Wide Swath	Çok geniş alanları kapsar, düşük çözünürlüklü bölgeyi görüntüler.	20 m (Ground Range)
WW Wave Mode	Deniz dalgaları ve okyanus yüzey hareketleri gibi dinamik su kütlelerini izlemek için kullanılır.	5 m (Ground Range)

Çizelge 2.3: Polarizasyon türleri ve görüntüleme modlarının özellikleri


Yukarıda açıklanan filtreleme parametreleri belirlendikten sonra, Copernicus Browser arayüzü üzerinden incelenmek istenen coğrafi bölge seçilmiş ve önceden tanımlanan tarih aralığı esas alınarak bu bölgeye ait Sentinel-1 görüntüleri listelenmiştir. Böylece çalışmanın kapsamına uygun, mekânsal ve zamansal açıdan hedeflenen kriterleri karşılayan görüntülerin sistematik biçimde derlenmesi sağlanmıştır.



Şekil 2.2: Veri indirme süreçleri.


Platform üzerinde listelenen görüntüler, indirme işlemi gerçekleştirilmeden önce ön izleme görselleri ve eşlik eden meta veri içerikleri aracılığıyla incelenebilmektedir; bu sayede uygun olmayan ya da çalışmanın amacına hizmet etmeyen sahnelerin önceden elenmesi mümkün olmaktadır. Bu kapsamda, yoğun deniz trafiğine sahip ve coğrafi açıdan birbirinden farklı bölgelerden toplam yaklaşık 70 adet büyük ölçekli SAR sahnesi seçilmiştir. Seçilen bölgeler arasında Çin ve Japonya'nın kıyı ve açık deniz alanları, Manş Denizi, Şanghay, Rotterdam, Bangkok ve Jebel Ali gibi yüksek hacimli liman bölgeleri, Kaliningrad kıyı şeridi ve Akdeniz suları yer almaktadır. Seçilen sahnelerin her biri ortalama olarak yaklaşık 150 km²'lik bir alanı kapsamakta; orijinal görüntü boyutları yaklaşık 24000×16000 piksel düzeyinde olup mekânsal çözünürlükleri 1m ile 15 m arasında değişmektedir. Bu coğrafi ve çevresel çeşitlilik, deniz durumu, kıyı morfolojisi ve gemilerin mekânsal dağılımı bakımından önemli ölçüde değişkenlik sağlamak ve böylece geliştirilen yöntemin birbirinden farklı koşullar altında sınanabilmesine olanak tanımaktadır.

Oluşturulan ön işleme hattı, büyük ölçekli SAR görüntülerine özgü temel zorlukların giderilmesine yönelik olarak tasarlanmıştır. İlk aşamada, başlangıçta tek bantlı ve 16-bit formatındaki GeoTIFF görüntüler, dinamik aralığın korunması ve yaygın derin öğrenme framework'leriyle uyumluluğun sağlanması amacıyla histogram eşitleme (histogram equalization) işlemine tabi tutularak GDAL [29] kütüphanesi yardımıyla üç kanallı 8-bit JPEG formatına dönüştürülmüştür. İkinci aşamada, her bir büyük SAR sahnesi sistematik bir şekilde, birbiriyle örtüşmeyen 800×800 piksel boyutundaki parçalara ayrılmış ve bu işlem sonucunda sahne başına yaklaşık 600 adet parça elde edilmiştir. Belirlenen bu parça boyutu, hesaplama açısından işlenebilirlik ile özellikle kıyı bölgelerinde belirleyici öneme sahip olan gemi–deniz–kara etkileşimlerinin modellenenebilmesi için gerekli olan mekânsal bağlamın korunması arasında dengeli bir orta nokta oluşturmaktadır. SAR görüntülerine özgü çarpımsal nitelikteki benek (speckle) gürültüsünün azaltılması amacıyla veri kümesi üzerinde Real-ESRGAN yöntemi uygulanmıştır; bu yöntem, esasen çözünürlük artırma için geliştirilmiş olmakla birlikte, bu çalışmada gürültü bastırma amacına uyarlanmış derin öğrenme tabanlı bir süper çözünürlük mimarisidir. İnce yapısal ayrıntıları aşırı ölçüde yumuşatma eğilimi gösteren geleneksel benek filtrelerinin aksine, Real-ESRGAN küçük gemilere ait konturları ve kenar keskinliğini koruyabilmekte, buna karşın arka plandaki istenmeyen artefaktları etkili biçimde bastırabilmektedir. Yapılan görsel incelemeler, gemi ile deniz arasındaki kontrastın belirgin biçimde iyileştiğini ve kıyı sınırlarının daha net hâle geldiğini doğrulamıştır. Ayrıca klasik özellik çıkarıcılar kullanılarak gürültüsü giderilmiş görüntüler üzerinde gerçekleştirilen ön denemeler, %8 ile %12 arasında değişen bir doğruluk artışı ortaya koymuş ve bu sonuçlar, benimsenen ön işleme stratejisinin etkinliğini destekler nitelikte olmuştur.




Şekil 2.3: Ön işleme sonucu elde edilen görüntü.

Veri kümesini oluşturan görüntülerin yaklaşık %40'ı kıyı ya da kıyıya yakın bölgeleri içermektedir. Bu oran, SSDD veri kümesi için tipik olarak rapor edilen %10–15 düzeyindeki kıyı kapsamının belirgin biçimde üzerinde yer almaktadır. Kıyı bölgelerinin karmaşıklığına yönelik bu bilinçli vurgu, operasyonel SAR deniz gözetiminde hâlen önemli bir güçlük olarak varlığını sürdüren gemi–kara karışıklığı (ship–land confusion) sorununun çok daha titiz ve gerçekçi biçimde değerlendirilebilmesine olanak tanımaktadır.




Şekil 2.4: Veritabanı oluşturulma süreci.

JPEG formatına dönüştürülen ve yaklaşık 24000×16000 piksel boyutuna sahip olan bu büyük görüntüler, yukarıda da değinildiği üzere 800×800 piksel boyutundaki alt parçalara bölünmüş ve her bir büyük görüntüden yaklaşık 600 adet alt görüntü elde edilmiştir (Şekil 2.5).



Şekil 2.5: Parçalanmış bir uydu görüntüsü.

Bu bölme işleminin temel gerekçesi; büyük boyutlu görüntülerin gerektirdiği yüksek bellek ve işlem gücü ihtiyacının azaltılması, veri yönetiminin kolaylaştırılması ve genel işlem veriminin artırılmasıdır. Bu yaklaşım sayesinde, hesaplama kaynaklarının daha verimli kullanılması ve eğitim sürecinin pratik açıdan uygulanabilir hâle getirilmesi amaçlanmıştır (Şekil 2.6).




Şekil 2.6: Parçalanmış görüntülerin nihai halleri.

Bölme işlemi sonucunda elde edilen yamalar, görselleştirme ve arşivleme gereksinimleri doğrultusunda JPEG formatına dönüştürülmüştür. Görüntü işleme adımlarının ardından yürütülen etiketleme sürecinde, veri kümesindeki tüm görüntü parçaları SAR alanında uzmanlığa sahip kişilerin gözetimi altında manuel olarak etiketlenmiş; etiketlerin mekânsal doğruluğunun denetlenmesinde ise Google Earth platformundan yararlanılmıştır (Şekil 2.7). Ağırlıklı olarak sınırlayıcı kutu (bounding box) anotasyonlarına dayanan SSDD ve benzeri veri kümelerinden farklı olarak, bu çalışmada oluşturulan veri seti deniz, kara ve gemi olmak üzere üç sınıf için piksel düzeyinde anlamsal etiketler sunmaktadır. Bu özellik, veri kümesini doğrudan anlamsal segmentasyon (semantic segmentation) ve çok görevli öğrenme (multi-task learning) çalışmalarına uygun hâle getirmektedir.


Kara bölgelerinin açık ve ayrı bir sınıf olarak etiketlenmesi, çalışmanın özellikle önem verdiği noktalardan biridir. Zira SAR gemi tespiti literatüründe kara alanları çoğunlukla bağımsız bir sınıf olarak ele alınmamakta; buna karşın kıyı senaryolarında ortaya çıkan yanlış alarmların (false alarm) başlıca kaynaklarından birini oluşturmaktadır. Bu nedenle kara sınıfının açıkça tanımlanması, kıyı bölgelerine ilişkin hataların azaltılması açısından belirgin bir katkı sağlamaktadır. Veri kümesinin nihai sürümü, 10 adet Sentinel-1

IW sahnesinden türetilmiş olup her biri 800×800 piksel mekânsal çözünürlüğe sahip toplam 8.658 adet etiketlenmiş SAR görüntü parçasından meydana gelmektedir.



Şekil 2.7: Görüntülerin etiketlenme süreci

Şekil 2.7’de görüldüğü üzere arayüz üzerinden nokta bazlı hassas etiketleme yapılmıştır. İleriki çalışmalarda faydalı olabileceği düşünülerek gemilerin dışında kara bölgeleri de farklı renkle (mavi) işaretlenmiştir. Emin olunamayan nesnelerde ise WS (weak ship) olarak etiketleme yapılmıştır.



Şekil 2.8: Etiketlenmiş örnek bir gemi nesnesi

Nokta bazlı etiketleme, piksel sınırlarını daha doğru ve hassas bir şekilde tanımlanmasında büyük önem arz etmektedir. Şekil 2.8’de ise bu nokta bazlı etiketlemeye ait örnek bir gemi nesnesi verilmiştir.

Görüntü işleme ve etiketleme aşamaları tamamlandıktan sonra veri kümesi, gemi içeren sahnelerin, kıyı bölgelerinin ve açık deniz sahnelerinin tüm alt kümelerde orantılı biçimde temsil edilmesini güvence altına almak amacıyla tabakalı örnekleme (stratified sampling) yöntemi kullanılarak üç ayrı alt kümeye ayrılmıştır. Bu ayırım sonucunda veri kümesinin %70’i (6060 görüntü) eğitim, %15’i (1299 görüntü) doğrulama ve kalan %15’i (1299 görüntü) ise test kümesi olarak tahsis edilmiştir. Benimsenen bu strateji, eğitim ve değerlendirme aşamaları arasında ortaya çıkabilecek dağılım kaymasını (distribution shift) en aza indirmekte ve böylece elde edilen performans değerlendirmelerinin güvenilirliğini artırmaktadır.

Genel bir değerlendirmeye, bu çalışmada önerilen veri kümesi SSDD ile karşılaştırıldığında üç temel üstünlük ortaya koymaktadır: açık deniz, kara ve gemi sınıflarını kapsayan piksel düzeyindeki ayrıntılı anotasyonlar, belirgin biçimde artırılmış kıyı sahne karmaşıklığı ve küçük ölçekli gemilerin zengin biçimde temsil edilmesi. Bu nitelikler, söz konusu veri kümesini; zorlu ve gerçek dünya koşullarını yansıtan SAR gemi tespiti senaryoları altında, gelişmiş segmentasyon mimarilerinin ve çok görevli öğrenme stratejilerinin sınanması açısından özellikle elverişli kılmaktadır.

3. MATERYAL VE METOT

Bu bölümde SAR görüntülerinden gemi tespitine yönelik iki farklı yaklaşım bir arada ele alınmış; bu doğrultuda özgün olarak derlenen bir veri seti üzerinde hem derin öğrenme tabanlı hem de matematiksel görüntü işleme tabanlı yöntemler incelenmiştir. Derin öğrenme tarafında, nesne tespiti alanında yaygın biçimde kullanılan YOLO mimarisi referans model olarak tercih edilmiş; ancak bu tercih, YOLO'nun birincil çözüm olarak önerilmesinden değil, karşılaştırmalı bir değerlendirme zemini oluşturma amacından kaynaklanmaktadır. Çalışmanın asıl odağını ise Hessian matrisi ve türetilen özdeğerlere dayanan tensör tabanlı matematiksel görüntü işleme yaklaşımı oluşturmaktadır. SAR görüntülerindeki gemi bölgelerine ait pikseller, uzamsal süreklilik ve komşuluk ilişkileri sergilemekte olup bu özellikler, Hessian matrisinden türetilen özdeğer matrislerine yansımaktadır.

İlk bakışta, temel bir eşikleme işlemiyle SAR görüntüsündeki parlak gemi piksellerini karanlık deniz arka planından ayırmanın mümkün olduğu düşünülebilir. Bu zorlukların üstesinden gelmek amacıyla, tensör tabanlı gemi tespitine yönelik bir ön koşul olarak özgün bir kara/deniz ayrımı yöntemi geliştirilmiştir. Söz konusu matematiksel yaklaşımın, derin öğrenme modellerine kıyasla daha hızlı işlem süresi ve daha yüksek tespit kesinliği sunduğu öngörülmekte; bu hipotez, iki yöntem arasında gerçekleştirilecek deneysel karşılaştırma ile sınanmaktadır.

Görüntü işleme yöntemlerinden elde edilen özellik vektörleri yapay sinir ağları ve destek vektör makineleri kullanılarak sınıflandırılmıştır. Gri seviye eş oluşturma matrisinden elde edilen özellik vektörleri destek vektör makineleri ile sınıflandırılmıştır. Türev ve histogram bilgisi temelli elde edilen özellik vektörleri ise yapay sinir ağları ile sınıflandırılmıştır. Böylece gemi tespitinde etkin ve hızlı sonuçları sunan farklı yöntemler ve sınıflandırıcılar karşılaştırılmıştır.

Bu bölümde ilk olarak Hessian matrisi ve türetilen özdeğerlere dayanan tensör tabanlı matematiksel görüntü işleme yaklaşımına değinilmiştir. Daha sonrasında derin öğrenme modellerinden biri olan YOLO mimarisi ve çalışma stratejisi hakkında kısaca bilgilere yer verilmiştir.

3.1 Gaussian Olasılığı ve Özdeğer Analizine Dayalı Model ile Gemi Tespiti

Gemi bölgelerindeki pikseller, uzamsal süreklilik ve komşuluk ilişkileri sergilemekte olup bu özellikler, Hessian matrisinden türetilen özdeğer matrislerine yansımaktadır. İlk bakışta, SAR görüntüsündeki parlak gemi piksellerinin koyu deniz arka planından temel bir eşikleme işlemiyle ayrılmasının mümkün olduğu düşünülebilir. Bu güçlüklerin üstesinden gelmek amacıyla, Hessian matrisi ve özdeğerlerini kullanan tensör tabanlı gemi tespiti ökoşul niteliğinde özgün bir kara/deniz ayırım yöntemi geliştirilmiştir.

SAR görüntülerinde, gemi bölgelerinden ve arka plan alanlarından kaynaklanan bazı ışık yansımaları örtüşebilmektedir. SAR görüntülerinin Hessian matrisi, piksel varyasyon bilgilerini kodlama kapasitesine sahiptir. Gri tonlamalı bir görüntü gibi iki boyutlu bir f skaler fonksiyonu için Hessian matrisi aşağıdaki şekilde tanımlanmaktadır [30]:

$$H_{\sigma}(x, y) = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial x \partial y} \\ \frac{\partial^2 I}{\partial y \partial x} & \frac{\partial^2 I}{\partial y^2} \end{bmatrix} = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{yx} & I_{yy} \end{bmatrix} \quad (3.1)$$

Burada $H_{\sigma}(x, y)$, Hessian matrisini; I_{xx} , I_{yy} ve I_{xy} sırasıyla görüntünün x-yönündeki, y-yönündeki ve çapraz yöndeki ikinci türev matrislerini göstermektedir. Uygulamada, Hessian matrislerinin hesaplanmasında Gauss fonksiyonundan türetilen türev filtreleri kullanılmaktadır. λ_1 ve λ_2 özdeğerlerini elde etmek için karakteristik denklem çözülmektedir:

$$\det(H - \lambda I) = 0 \quad (3.2)$$

Bu denklem, aşağıdaki ikinci dereceden denkleme dönüşmektedir:

$$\lambda^2 - \text{Tr}(H)\lambda + \det(H) = 0 \quad (3.3)$$

Burada $\text{Tr}(H) = I_{xx} + I_{yy}$ matrisin izini (trace) ve $\det(H) = I_{xx}I_{yy} - I_{xy}^2$ determinantını temsil etmektedir. Buna göre Hessian matrisinin özdeğerleri şu şekilde hesaplanmaktadır:

$$\lambda_{1,2} = \frac{(I_{xx} + I_{yy}) \pm \sqrt{(I_{xx} - I_{yy})^2 + 4I_{xy}^2}}{2} \quad (3.4)$$

Bu çalışmada, kara/deniz ayırım yöntemi için yalnızca ikinci özdeğer (λ_2) kullanılmıştır. Bunun temel nedeni, görüntüdeki varyasyon büyüklüğünün en etkin biçimde ikinci özdeğer tarafından temsil edilmesidir. İkinci özdeğer görüntüsüne, standart sapması $\sigma = 2$ olan bir Gauss filtresi uygulanarak ortalama alınmış bir görüntü elde edilmektedir. Bu işlemde kullanılan Gauss fonksiyonu şu şekilde tanımlanmaktadır:

$$g_{\sigma,\mu} = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) \quad (3.5)$$

Burada σ ve μ sırasıyla Gauss fonksiyonunun standart sapma ve ortalama değerlerini ifade etmektedir. Önerilen yöntemde Gauss filtrelemesi, ikinci özdeğere karşılık gelen λ_2 görüntüsüne uygulanarak filtrelenmiş $G(\lambda_2)$ görüntüsü elde edilmektedir. Ardından, yerel varyansı ölçmek amacıyla ikinci özdeğer görüntüsü ile filtrelenmiş özdeğer bilgisi arasındaki fark hesaplanmaktadır. Bu işlem aşağıdaki ifadeyle gösterilmektedir:

$$SS = \sqrt{g_{\sigma,\mu}(\lambda_2 - MU)^2} \quad (3.6)$$

Burada SS , ikinci özdeğer görüntüsünün yerel standart sapma haritasını temsil etmektedir. MU ve SS görüntülerinin standart sapma değerleri ayrı ayrı hesaplanarak sMU ve sSS elde edilmektedir. Son olarak, bu iki görüntünün olasılık yoğunlukları aşağıdaki şekilde hesaplanmaktadır:

$$Pmu = \exp(-MU^2/(2sMU^2)) \quad (3.7)$$

$$Pss = \exp(-SS^2/(2sSS^2)) \quad (3.8)$$


Uygulanan işlemler aracılığıyla Gauss tabanlı bir olasılık haritası oluşturularak görüntü belirginliği ve varyansı normalleştirilmektedir. Bu haritada düşük yoğunluklu bölgeler (deniz alanları) yüksek olasılık değerleri (1'e yakın) sergilerken, yüksek yoğunluklu bölgeler (kıyı şeridi veya gemi alanları) düşük olasılık değerlerine (0'a yakın) sahiptir. Bu yaklaşım, yalnızca kara/deniz ayırımını kolaylaştırmakla kalmayıp aynı zamanda gemi bölgelerinin görsel belirginliğini de artırmaktadır. Deneysel sonuçlar, 0.7 eşik değerinin

uygulanmasının genel olarak en doğru kara/deniz ayrımını sağladığını ve kıyı şeridini etkin biçimde belirlediğini ortaya koymaktadır. Elde edilen görüntülerin eşiklenmesi ve birleştirilmesi için aşağıdaki ifadeden yararlanılmaktadır:

$$result = (Pmu > 0.7) \& (Pss > 0.7) \quad (3.9)$$

Burada *Pmu* ve *Pss* sırasıyla ortalama görüntüyü ve standart sapma görüntüsünü temsil etmektedir. Eşikleme işleminin ardından bu iki görüntü mantıksal VE (AND) işlemiyle birleştirilmektedir. Elde edilen *result* görüntüsü normalleştirilerek yalnızca 0 ve 255 değerlerinden oluşan ikili siyah-beyaz bir görüntüye dönüştürülmektedir. Bir sonraki aşamada, *result* görüntüsünde yalnızca en büyük nesneyi elde tutmak amacıyla kontur tespiti gerçekleştirilmektedir. Bu amaçla OpenCV kütüphanesinin *findContours* yöntemi kullanılmaktadır. Söz konusu yöntem iki temel parametre ile uygulanmaktadır: **RETR_EXTERNAL** parametresi: İç konturlar göz ardı edilerek yalnızca nesneyi çevreleyen dış konturun hesaplanmasını sağlamaktadır.


CHAIN_APPROX_SIMPLE parametresi: Yatay, dikey ve çapraz segmentleri sıkıştırarak yalnızca konturun anahtar noktalarını korumak suretiyle bellek kullanımını ve işlem verimliliğini optimize etmektedir. Şekil 3.1 önerilen yöntemin kara bölgesi içeren bir SAR görüntüsüne uygulanmasıyla elde edilen sonuçları göstermektedir.



Şekil 3.1: Morfolojik işlemler sonucu oluşan ikili siyah-beyaz görüntüler.

Önceki adımda gerçekleştirilen kara/deniz ayrımı sayesinde, görüntü içindeki gemilere yönelik arama alanı önemli ölçüde daraltılmıştır. Şekil 3.2(b)'de görüldüğü üzere, gemiler artık denizi temsil eden beyaz bölgeler içinde daha kolay tespit edilebilmektedir. Önerilen yöntemin bu aşamasında, gri tonlamalı giriş görüntüsü, bir önceki adımda elde

edilen ikili kara/deniz maskesiyle çarpılmaktadır (Şekil 3.2 (b)). Bu çarpım işlemi sonucunda giriş görüntüsündeki kara bölgeleri siyaha dönüştürülürken deniz bölgesi içindeki gemi pikselleri ön plana çıkarılmaktadır (Şekil 3.2 (c)). Şekil 3.2 (c)'den elde edilen görüntüler üzerinde yürütülen deneysel çalışmalarda, kullanılan veri kümesinde bölütleme için yaklaşık 140 piksel yoğunluğu eşik değerinin etkin sonuçlar verdiği görülmüştür.



Şekil 3.2: Tespit edilmesi beklenen gemi nesneleri.

Bununla birlikte SAR görüntüleme modundan kaynaklanan su izleri, yansımalar veya gürültü gibi etkenler nedeniyle istenmeyen pikseller, tespit edilen gemilerin özellikle önünde, arkasında veya yan kısımlarında kalıcı olarak bulunabilmektedir. Bu komşu beyaz pikselleri gidermek amacıyla morfolojik erozyon işlemi ile `binary_fill_holes` fonksiyonundan yararlanılmaktadır. Morfolojik işlemler aracılığıyla istenmeyen piksellerin temizlenmesinin ardından, son aşamada temizlenmiş ikili görüntülerdeki gemiler tespit edilerek sınır ve etiket bilgileri belirlenmektedir. Bu işlem, bağlantılı bileşen etiketleme teknikleriyle gerçekleştirilmektedir. Bu amaçla, tespit edilen gemilerin konumlarını, piksel tabanlı alanlarını ve sayılarını ilgili etiket bilgileriyle birlikte belirlemek için SciPy kütüphanesinin `binary_fill_holes` fonksiyonundan yararlanılmaktadır.

Morfolojik işlemler sayesinde istenmeyen pixel'lerin kaldırılmasından sonra son aşama olarak gemilerin tespit edilmesi ve sınırlarının ve etiket bilgilerinin sağlanması kalmaktadır. Bu işlem, bağlantılı bileşen etiketleme teknikleriyle gerçekleştirilmektedir. Bu amaçla, tespit edilen gemilerin konumlarını, piksel tabanlı alanlarını ve sayılarını ilgili etiket bilgileriyle birlikte belirlemek için SciPy kütüphanesinin `label` yöntemi ikili görüntüye uygulanmaktadır.

3.2 Derin Öğrenme Modelleri

Derin öğrenme, yapay sinir ağlarının çok katmanlı mimariler aracılığıyla ham veriden hiyerarşik temsiller öğrenmesini sağlayan bir makine öğrenmesi alt alanıdır. Klasik makine öğrenmesi yöntemlerinden temel farkı, öznitelik mühendisliğine olan bağımlılığı ortadan kaldırmasında yatmaktadır; zira geleneksel yaklaşımlarda bir uzman tarafından elle tasarlanması gereken öznitelikler, derin öğrenme modellerinde doğrudan veriden otomatik olarak öğrenilmektedir. Bu özellik, derin öğrenmeyi özellikle görüntü işleme, doğal dil işleme ve ses tanıma gibi yüksek boyutlu ve yapısal karmaşıklığa sahip alanlarda üstün kılmaktadır.

Derin öğrenme modellerinin temel yapı taşı olan yapay sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Bir sinir ağı; girdi katmanı, bir veya birden fazla gizli katman ve çıktı katmanından oluşmaktadır. Her katmandaki nöronlar, bir önceki katmandan gelen girdilerin ağırlıklı toplamını hesaplar ve bu toplamı doğrusal olmayan bir aktivasyon fonksiyonundan geçirerek bir sonraki katmana iletir. Matematiksel olarak, l . katmandaki bir nöronun çıktısı şu şekilde ifade edilir:

$$a^{(l)} = f\left(\sum_j w_j^{(l)} \cdot a_j^{(l-1)} + b^{(l)}\right) \quad (3.10)$$

Burada $w_j^{(l)}$ ağırlık katsayılarını, $b^{(l)}$ sapmayı (bias), $a_j^{(l-1)}$ bir önceki katmandaki nöron çıktıları ve $f()$ aktivasyon fonksiyonunu temsil etmektedir.

Sıkça kullanılan aktivasyon fonksiyonları arasında sigmoid, hiperbolik tanjant ve özellikle derin ağlarda kaybolma gradyanı sorununu hafifletmesiyle öne çıkan ReLU (Rectified Linear Unit) yer almaktadır:

$$ReLU(x) = \max(0, x) \quad (3.11)$$

Modelin öğrenmesi, kayıp fonksiyonunun minimize edilmesiyle gerçekleştirilir. Sınıflandırma görevlerinde yaygın olarak kullanılan çapraz entropi kayıp fonksiyonu şu şekilde tanımlanır:

$$L = -\sum_{c=1}^c y_c \log(y'_c) \quad (3.12)$$

Burada y_c gerçek sınıf etiketini, y'_c ise modelin tahmin ettiği olasılık değerini ifade etmekte; C ise toplam sınıf sayısını göstermektedir. Bu kayıp fonksiyonunun ağırlıklara göre minimize edilmesi, geri yayılım (backpropagation) algoritması ile gerçekleştirilir. Geri yayılımda zincir kuralı uygulanarak her ağırlığın kayıp fonksiyonu üzerindeki etkisi hesaplanmakta ve ağırlıklar gradyan iniş yöntemiyle güncellenmektedir:

$$\mathbf{w}^{(l)} \leftarrow \mathbf{w}^{(l)} - n \cdot \frac{\partial L}{\partial \mathbf{w}^{(l)}} \quad (3.13)$$

Burada n öğrenme hızını (learning rate) ifade etmektedir.

Görüntü işleme görevleri söz konusu olduğunda, tam bağlantılı ağların yetersiz kaldığı durumlar için Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN) geliştirilmiştir. CNN'ler; evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardan oluşan bir hiyerarşi üzerine inşa edilmiştir. Evrişim katmanında, girdi görüntüsü üzerine öğrenilebilir filtreler (çekirdekler) uygulanarak öznitelik haritaları elde edilmektedir.

Havuzlama katmanları ise uzamsal boyutu küçülterek hesaplama yükünü azaltmakta ve modelin öteleme değişmezliğini (translation invariance) artırmaktadır. Maksimum havuzlama (max pooling) bu amaçla en yaygın kullanılan yöntemdir.

Derin CNN mimarileri, katman sayısı arttıkça giderek daha soyut ve anlamlı öznitelikler öğrenebilmektedir. İlk katmanlar kenar ve köşe gibi düşük seviyeli özellikleri yakalarken, derinlere inildikçe nesne parçaları ve bütünleşik yapılar gibi yüksek seviyeli temsiller elde edilmektedir. Bu hiyerarşik öğrenme kapasitesi, derin öğrenme modellerini nesne tespiti, segmentasyon ve sınıflandırma gibi karmaşık görsel görevlerde son derece etkili kılmaktadır.

3.2.1 You Only Look Once (YOLO)

Bu bölümde kıyaslama yapabilmek amacıyla seçilen ve derin öğrenme mimarilerinden olan YOLOv26'nın [31] ve YOLOv12'nin [32] üretilen veri seti ile eğitilmesine değinilecektir. Elde edilen sonuçlar önerilen modelle kıyaslamak için önemlidir. Nesne tespiti, bir görüntü içindeki nesnelerin hem sınıflandırılmasını hem de konumlandırılmasını eş zamanlı olarak gerçekleştirmeyi amaçlayan bir bilgisayarla görme görevidir. Bu alanda tarihsel süreç incelendiğinde, erken dönem yöntemlerinin bölge önerisi (region proposal) tabanlı iki aşamalı bir yapı üzerine kurulduğu görülmektedir. R-CNN ve

türevleri bu kategorinin en bilinen temsilcileridir; ancak söz konusu yaklaşımlar, aday bölgelerin ayrı bir aşamada üretilmesinden kaynaklanan yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalar için yetersiz kalmaktadır. Bu kısıtlamayı aşmak amacıyla Redmon ve ark. tarafından 2016 yılında önerilen YOLO mimarisi, nesne tespiti tek bir geçişte (single-pass) çözülebilir bir regresyon problemi olarak yeniden kurgulanmış ve alandaki paradigma değişiminin öncüsü olmuştur.

YOLO'nun temel fikri, girdi görüntüsünü $S \times S$ boyutlu bir ızgaraya bölmek ve her bir ızgara hücresi için nesne tespiti tahminlerini doğrudan üretmektir. Her ızgara hücresi, B adet sınırlayıcı kutu (bounding box) ve bu kutulara ait güven skorları ile C sınıfa ait koşullu olasılık değerlerini tahmin etmektedir. Güven skoru, hem bir nesnenin o kutuda bulunup bulunmadığını hem de kutunun doğruluk kalitesini yansıtmaktadır.

Mimarinin omurgası (backbone), görüntüden hiyerarşik öznitelikleri çıkarmakla görevli derin bir CNN'den oluşmaktadır. Orijinal YOLOv1 mimarisinde GoogLeNet'ten ilham alınan 24 evrişim katmanı ve 2 tam bağlantılı katman kullanılmıştır. Sonraki sürümlerde bu omurga, YOLOv2'de Darknet-19, YOLOv3'te Darknet-53, YOLOv4 ve sonrasında ise CSPDarknet gibi daha güçlü mimarilerle değiştirilmiştir. Ayrıca YOLOv3 ile birlikte çok ölçekli tespit (multi-scale detection) mekanizması tanıtılmış; ağ farklı çözünürlüklerdeki öznitelik haritaları üzerinden tahmin üreterek küçük, orta ve büyük nesneleri eş zamanlı olarak tespit edebilir hale gelmiştir.

Tahmin aşamasında, modelin ürettiği çok sayıda örtüşen kutu arasından en anlamlı olanını seçmek için maksimum baskılama (Non-Maximum Suppression, NMS) algoritması uygulanmaktadır. Bu süreçte önce belirli bir güven eşiğinin altındaki kutular elenmekte, ardından aynı nesneyi tarif eden yüksek IoU değerine sahip kutular arasından yalnızca en yüksek güven skoruna sahip olanı korunmaktadır. YOLO'nun tek geçişli yapısı sayesinde tüm bu süreç son derece hızlı tamamlanmakta; modern versiyonları gerçek zamanlı uygulamalarda saniyede yüzlerce kare işleyebilme kapasitesine ulaşmaktadır. Bununla birlikte, derin öğrenme modellerinin yapısal gereği olan büyük etiketli veri seti ihtiyacı, yoğun hesaplama kaynağı gereksinimleri ve karar mekanizmalarının yorumlanabilirliğinin sınırlı olması, bu yaklaşımın temel kısıtlılıklarını oluşturmaktadır. Söz konusu kısıtlılıklar, özellikle veri temini ve hesaplama verimliliğinin ön planda olduğu uygulamalarda matematiksel görüntü işleme yöntemlerinin hâlâ rekabetçi bir alternatif oluşturduğunu ortaya koymaktadır.


3.2.2 YOLOv26 Model Mimarisi

Bu çalışmada, Ocak 2026'da Ultralytics tarafından yayımlanan en güncel model olan Ultralytics YOLO26, SAR görüntüleri üzerinde gemi ve kara tespiti amacıyla kullanılmıştır (Şekil 3.3).

Üretilen birçok modelin ardından versiyon 26'da aşağıdaki yenilikler eklenmiştir:

- End-to-end NMS-free inference: Geleneksel Non-Maximum Suppression (NMS) son işlem adımı kaldırılarak uçtan uca çıkarım sağlanmıştır. Bu, küçük ve birbirine yakın nesnelerin tespitinde özellikle avantaj sağlamaktadır.
- Edge deployment optimizasyonu: Düşük güçlü cihazlarda çalışabilecek şekilde optimize edilmiş mimari tasarım.
- Gelişmiş feature pyramid: Çok ölçekli özellik çıkarımı iyileştirilerek farklı boyutlardaki nesnelerin eşzamanlı tespiti kolaylaştırılmıştır.
- Geniş görev desteği: Tespit (detection), segmentasyon, sınıflandırma, poz tahmini ve yönelimli bounding box (OBB) görevlerinin tek bir çatı altında desteklenmesi.

Bu çalışmada YOLO26m (Medium) varyantı tercih edilmiştir. Medium modeli yaklaşık 20 milyon parametreye sahip olup, doğruluk ve çıkarım hızı arasında optimum denge sağlamaktadır. Önceden eğitilmiş (pretrained) ağırlıklar ile transfer öğrenme uygulanmıştır.




Şekil 3.3: YOLOv26 sistem mimarisi.

3.2.3 YOLOv12 Model Mimarisi

YOLOv12, Ultralytics tarafından Şubat 2025'te yayımlanan ve dikkat (attention) mekanizmasını YOLO mimarisine doğrudan entegre eden bir nesne tespit modelidir. Önceki YOLO sürümlerinden temel ayrımı; alan dikkat modülü (Area Attention, A2-Module) ve Artıklı Verimli Katman Toplama Ağları (Residual Efficient Layer Aggregation Networks, R-ELAN) bloklarının kullanılmasıdır. Bu tasarım, modelin uzun mesafeli uzamsal bağımlılıkları yakalamasını sağlarken hesaplama maliyetini kabul edilebilir düzeyde tutmaktadır.

YOLOv12; N, S, M, L ve X olmak üzere beş farklı büyüklük varyantıyla sunulmaktadır. Bu çalışmada, model kapasitesi ile çıkarım hızı arasında dengeli bir yapı sunan YOLOv12m (Medium) varyantı tercih edilmiştir. YOLOv12m yaklaşık 20 milyon parametreye sahip olup SAR gemi tespiti gibi zorlu görevlerde yeterli temsil kapasitesi sağlamaktadır. Dikkat mekanizmasına sahip olmasından dolayı bu çalışmada kullanılmıştır.



Şekil 3.4: YOLOv12 sistem mimarisi.

3.2.4 Eğitim Parametreleri

Model eğitiminde kullanılan hiperparametreler Çizelge 3.1’de sunulmaktadır. Her bir parametrenin eğitim sürecindeki rolü aşağıda açıklanmıştır.

Parametre	Değer	Açıklama
model	yolo26m.pt	COCO üzerinde pretrained Medium model
imgsz	800	Ağa verilen görüntü boyutu (piksel). Orijinal SAR görüntü boyutuyla eşleştirilmiştir.
batch	16	Her iterasyonda işlenen görüntü sayısı. GPU belleği ile uyumlu olacak şekilde belirlenmiştir.
epochs	100	Maksimum eğitim döngüsü sayısı.
patience	15	Early stopping sabır değeri. 15 epoch boyunca iyileşme olmazsa eğitim durdurulur.
optimizer	auto (MuSGD)	Optimizasyon algoritması. Ultralytics'in otomatik seçimi ile öğrenme oranı ve momentum otomatik ayarlanmıştır.
lr0	0.01	Başlangıç öğrenme oranı
cos_lr	True	Kosinüs öğrenme oranı çizelgesi. Eğitim ilerledikçe öğrenme oranını kademeli olarak düşürür.
amp	True	Automatic Mixed Precision. FP16/FP32 karma hassasiyet ile eğitimi hızlandırır ve bellek kullanımını azaltır.
mosaic	1.0	Mozaik veri artırma. 4 görüntüyü birleştirerek modele bağlamsal çeşitlilik sağlar.
close_mosaic	10	Son 10 epoch'ta mozaik kapatılarak modelin gerçek görüntü dağılımına uyum sağlaması hedeflenmiştir.
seed	42	Rastgelelik tohum değeri. Tekrar edilebilirlik için sabitlenmiştir.
device	0 (GPU)	NVIDIA GeForce RTX 5070 Ti (16 GB VRAM)

Çizelge 3.1: Eğitim parametreleri.

Optimizasyon stratejisi: Ultralytics'in optimizer=auto modu, model yapısına göre en uygun optimizasyon ve öğrenme oranını otomatik belirlemektedir. Bu eğitimde **MuSGD (lr=0.01, momentum=0.9)** seçilmiştir. Kosinüs annealing ile öğrenme oranı epoch boyunca 0.01'den kademeli olarak düşürülmüş, bu sayede eğitimin son aşamalarında daha ince ayar (fine-grained) optimizasyon sağlanmıştır.

Veri artırma (augmentation): Mozaik augmentation, dört farklı görüntüyü tek bir eğitim örneğinde birleştirerek modele farklı ölçek ve konumlardaki nesneleri aynı anda gösterme imkanı sunmaktadır. HSV renk uzayında rastgele dönüşümler ($h=0.015$, $s=0.7$, $v=0.4$), yatay çevirme ($flipr=0.5$) ve rastgele silme ($erasing=0.4$) ile modelin genelleme kabiliyeti güçlendirilmiştir.

Yolov26 ve Yolov12'de de doğru kıyasalanabilirlik sağlamak adına aynı parametreler ile eğitim süreci başlatılmıştır.

3.2.5 Eğitim Aşaması

Etiketler COCO JSON formatında, poligon segmentasyonu ve bounding box bilgileriyle birlikte saklanmıştır. Üç kategori tanımlanmıştır: **Land** (kara), **Ship** (gemi) ve **WS** (su yüzeyi/gemi izi). Eğitim aşamasında Ship ve WS kategorileri "Ship" sınıfı altında birleştirilmiştir. COCO formatındaki etiketler, YOLO'nun gerektirdiği normalize bounding box formatına dönüştürülmüştür. Veriseti, tekrar edilebilirlik amacıyla sabit rastgelelik tohumu (seed=42) kullanılarak **%80 eğitim, %15 doğrulama, %5 test** oranlarında bölünmüştür.

Küme	Görüntü Sayısı	Etiket Sayısı
Train	6495	~15377
Validation	1212	~2875
Test	411	~969
Toplam	8118	~19221

Çizelge 3.2: Eğitim için verilerin dağılımı.

İlk eğitim YoloV26 ile Ultralytics Python API'si kullanılarak başlatılmıştır ve NVIDIA GeForce RTX 5070 Ti ekran kartı üzerinde yaklaşık **3 saat 10 dakika** sürmüştür. Early stopping mekanizması devreye girerek eğitim **85. epoch'ta** sonlandırılmıştır; model 70. epoch civarında en iyi doğrulama performansına ulaşmıştır. Raporlama ve metrik ölçümleri için hem en iyi model (best.pt) hem de son üretilen model (last.pt) kaydedilmiştir.

İkinci eğitim YoloV12 ile yine Ultralytics Python API'si kullanılarak başlatılmıştır ve aynı NVIDIA GeForce RTX 5070 Ti ekran kartı üzerinde yaklaşık **5 saat 24 dakika** sürmüştür. Eğitim 100. epoch'ta sonlandırılmıştır. Raporlama ve metrik ölçümleri için ilk eğitimde olduğu gibi en iyi model ve üretilen son model beraber kaydedilmiştir.

```
python

from ultralytics import YOLO

model = YOLO("yolo26m.pt") # Pretrained ağırlıklar

results = model.train(
    data="dataset.yaml",
    epochs=100,
    imgsz=800,
    batch=16,
    patience=15,
    device=0,
    cos_lr=True,
    amp=True,
    close_mosaic=10,
    seed=42,
    plots=True,
)
```

Şekil 3.5: Python ile model eğitimi.

4. UYGULAMA VE DEĞERLENDİRME

Bu bölümde tez çalışmaları kapsamında literatürde mevcut olan ve tez çalışmalarında geliştirilen gemi veri tabanında ilk defa kullanılan Gaussian olasılığı ve özdeğer analizine ve derin öğrenme tabanlı yöntemlerin gemi sınıflandırma problemindeki başarıları deneysel olarak ele alınmıştır. İlk olarak kullanılan sınıflandırıcıların temel parametreleri hakkında bilgilere yer verilmiştir. Daha sonra performans değerlendirilmesinde kullanılan metrikler tanıtılmıştır. Daha sonra elde edilen sınıflandırma sonuçları sunulmuştur.

4.1 Sınıflandırıcı Parametreleri


Tez çalışmalarında ilk olarak Gaussian olasılığı ve özdeğer analizi tabanlı önerilen matematiksel yöntemle sınıflandırma işlemi gerçekleştirilmiştir. Ardından derin öğrenme modelleriyle (YOLO) sınıflandırma işlemi yapılmıştır. Modeller varsayılan, en bilinen ve yaygın kullanılan parametreleri ile kullanılmıştır. Kullanılan yapay sinir ağında veri seti, tekrar edilebilirlik amacıyla sabit rastgelelik tohumu (seed=42) kullanılarak **%80 eğitim, %15 doğrulama ve %5 test** oranlarında bölünmüştür.

Modellerden biri erken durdurma mekanizması sayesinde aşırı öğrenme davranışı göstermeden 85. Epoch'ta eğitim durdurulmuş ve en iyi sonuç 70. Epoch'ta alınmıştır. Diğer Yolo modeli ise 100 epoch boyunca eğitime devam edilmiştir.

Gaussian olasılığı ve özdeğer analizine dayalı önerilen yöntemde ise direkt olarak ön işleme yapılmış ve ardından model tarafından sınıflandırma işlemi başarıyla gerçekleştirilmiştir. Model matematiksel tabanlı olduğundan dolayı herhangi bir eğitim veri seti oluşturulmamıştır.

4.2 Değerlendirme Metrikleri

Makine öğrenmesi yöntemlerinin performansını ölçmek için farklı yöntemler kullanılmaktadır. Bunlardan biri olan karmaşıklık matrisi gerçek ve tahmin edilen değerleri karşılaştırma prensibine dayanmaktadır. Bu matristeki temel yapılar şunlardır: Doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN). Bu bilgiler algoritmanın yaptığı hataları ve doğruluğun ölçüsünü sunar. Bunlara ek olarak veri görselleştirmesi işleminde ve istatistiksel analizi işlemlerini anlamaya ve yorumlamaya da kolaylık sağlar.



Şekil 4.1: Karmaşıklık matrisi

Doğruluk (Accuracy): Bir sınıflandırma modelinin genel performansını değerlendirmek için başvuru temel ölçütlerden biridir. Modelin tüm örnekler üzerinde gerçekleştirdiği doğru tahminlerin, toplam örnek sayısına oranını ifade eder ve bu oran genellikle yüzde cinsinden raporlanır.

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru tahminlerin sayısı}}{\text{Toplam Tahminlerin Sayısı}} \quad (4.1)$$

Bununla birlikte, yalnızca doğruluk metriğine dayanan bir performans değerlendirmesi her koşulda güvenilir sonuçlar üretmez. Sınıflar arasındaki örnek dağılımının dengesiz olduğu veri kümelerinde bu metrik, modelin gerçek başarımını olduğundan yüksek gösterebilir ve yanıltıcı çıkarımlara zemin hazırlayabilir.

Bu sınırlılığı aşmak ve daha nesnel bir ölçüm gerçekleştirmek amacıyla aşağıdaki ifadeden de yararlanılmaktadır:

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.2)$$

Hassasiyet (Precision): Modelin pozitif olarak sınıflandırdığı örnekler arasında gerçekten pozitif olanların oranını ifade eden bir performans ölçütüdür. Başka bir deyişle, modelin pozitif yönlü tahminlerinin ne ölçüde isabetli olduğunu ortaya koyar. Matematiksel olarak,

doğru pozitif (TP) tahmin sayısının; doğru pozitif (TP) ve yanlış pozitif (FP) tahmin sayılarının toplamına bölünmesiyle elde edilir. Hassasiyet değeri, F1 Skoru'nun hesaplanmasında girdi olarak kullanılan temel bileşenlerden biri olma özelliğini de taşımaktadır.

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP + FP} \quad (4.3)$$

Duyarlılık (Recall): Veri kümesindeki tüm gerçek pozitif örnekler içinde sınıflandırıcı tarafından doğru biçimde pozitif olarak tanımlananların oranını ölçen bir metriktir. Bu oran, doğru pozitif (TP) örnek sayısının; doğru pozitif (TP) ve yanlış negatif (FN) örnek sayılarının toplamına bölünmesiyle hesaplanmakta olup ilgili matematiksel ifade aşağıda verilmektedir:

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN} \quad (4.4)$$

F1 Skoru: Hassasiyet ve duyarlılık metriklerini tek bir ölçüt altında birleştiren F1 Skoru, sınıflandırma modellerinin performansını daha bütüncül bir perspektiften değerlendirmeye olanak tanır. Daha önce ele alınan doğruluk metriği, sınıflar arasında dengeli bir örnek dağılımı varsaymaktadır; ancak gerçek dünya veri kümelerinin büyük çoğunluğunda bu koşul sağlanamamaktadır. Sınıf dengesizliğinin söz konusu olduğu durumlarda hassasiyet ve duyarlılık ölçütleri ön plana çıkmakta, F1 Skoru ise bu iki metriğin harmonik ortalaması alınarak hesaplanmakta ve böylece modelin performansına ilişkin daha güvenilir bir değerlendirme sunmaktadır. F1 Skoru'na ait matematiksel ifade aşağıda gösterilmektedir:

$$\text{F1 Skoru} = \frac{2 \times (\text{Hassasiyet} \times \text{Duyarlılık})}{(\text{Hassasiyet} + \text{Duyarlılık})} \quad (4.5)$$

4.3 Gaussian Olasılığı ve Özdeğer Analizine Dayalı Model ile Alınan Sonuçlar

Tezin bu bölümünde önerilen model olan, Gaussian Olasılığı ve Özdeğer Analizi tabanlı matematiksel modelin [23], oluşturulan veri seti üzerindeki performansına değinilmiştir. Kara ve kıyı şeridi ayrımı için Gauss fonksiyonu tabanlı yöntem, komşuluk değeri 3 olarak uygulanmıştır. Önerilen yöntemde sigma sabiti (σ) ve Gauss komşuluk sabiti, tüm veri kümesi boyunca aynı değerde kullanılmıştır. Bunun yanı sıra, standart sapma ve

ortalama görüntüleri için eşik değeri 0.7 olarak sabitlenmiş; bu sayede ek eşikleme tekniklerine ihtiyaç duyulmamıştır. Son olarak, gemi olmayan nesneleri temizlemek amacıyla morfolojik işlemlerin çekirdek boyutu tüm görüntüler için 2 olarak belirlenmiştir. Önerilen yöntem, piksel gri seviyesi varyasyonlarının özdeğerlerini analiz ederek hassas değişim bilgisini etkin biçimde kodlamaktadır. Veri tabanı ile ilgili görüntülerin kıyı/hedef oranı Çizelge 4.2’de verilmiştir. Deneysel çalışmalarda diğer bir karşılaştırma metriği olarak Figure of Merit (FoM) kullanılmıştır. FoM aşağıdaki formül ile hesaplanmaktadır:


$$FoM = \frac{N_c}{N_c + N_M + N_{FA}} \quad (4.6)$$

Burada N_C doğru tespit edilen gemi sayısını; N_{FA} ve N_M ise sırasıyla yanlış alarm sayısını ve ıskalanmış gemi tespit sayısını temsil etmektedir. Çizelge 4.1 sonuçlarından görüldüğü üzere, önerilen yöntem tüm test koşullarında yüksek FoM değerlerini elde etmiştir.

Gürültülü/Düşük kontrastlı görüntü (%)	Kıyı bölgesi görüntüsü (%)	Yoğun hedef görüntüsü (%)
100	100	94

Çizelge 4.1: Önerilen Model için elde edilen metrikler.

Şekil 4.2’de ilgili modelden elde edilen sınıflandırılmış örnek test görüntüleri yer almaktadır.



Şekil 4.2: Sonuçların diğer yöntemlerle kıyaslanması.

Şekil 4.2 satırları sırasıyla; gürültülü ve düşük kontrastlı SAR görüntüsünü (800x800), kıyı bölgesine ait SAR görüntüsünü (800x800), ve yoğun gemi hedeflerini içeren SAR görüntüsünü (800x800), göstermektedir. Mavi kutular gözden kaçan (tespit edilemeyen) gemileri, kırmızı kutular ise yanlış alarm durumlarını belirtmektedir.

- **(a), (e), (i) ve (m):** Yeşil kutularla gösterilen ve doğru kabul edilen (ground truth) gemi tespitlerinin yer aldığı orijinal SAR görüntüsü.
- **(b), (f), (j) ve (n):** SP-CFAR yöntemi [33]
- **(c), (g), (k) ve (o):** Bilgi geometrisi (Information geometry) yöntemi [34]
- **(d), (h), (l) ve (p):** Önerilen yöntem.

SP-CFAR yönteminde, SAR görüntülerinde gemi tespiti performansını artırmak amacıyla, geleneksel sabit yanlış alarm oranı (CFAR) algoritmalarının pencere topolojisini

değiştiren süperpiksel tabanlı yeni bir CFAR (SP-CFAR) yöntemi önerilmiştir. Klasik yöntemde arka plan deniz dağınıklığını (sea clutter) ve koruma bandını (guard band) tanımlamak için kullanılan dikdörtgen kayan pencereler yerine, görüntü algısal olarak benzer pencerelere bölütlenerek süperpikseller (SP) üzerinden işlem gerçekleştirilmiştir. Önerilen mimaride, SAR çözünürlüğü ve beklenen gemi boyutuna göre tasarlanan süperpiksel segmentasyonu sayesinde, test edilen pikseli içeren süperpikselin tamamı koruma bandı olarak kabul edilirken; bu süperpiksel ile sınır paylaşan komşu süperpikseller ise yerel arka planı oluşturmaktadır. Bu yaklaşım, gemi sınırlarının koruma bandı tarafından eksiksiz kapsanmasını sağlayarak hedef piksellerinin arka plan istatistiklerini kirlletmesini engellemekte ve yakın konumdaki birden fazla geminin varlığında ya da heterojen deniz yüzeylerinde yanlış alarm oranını düşürmeyi amaçlamaktadır.

Bilgi gemoterisi yönteminde, sentetik açıklıklı radar görüntülerinde homojen olmayan deniz arka planı ve gürültülerin yol açtığı yanlış alarmları azaltmak amacıyla, istatistiksel olasılık dağılımlarının geometrik yapısını kullanan bilgi geometrisi tabanlı bir gemi tespiti yöntemi geliştirilmiştir. Önerilen bu yaklaşımda, deniz dağınıklığının (sea clutter) modellenmesinde lognormal dağılım esas alınmış ve bu dağılım modeli Riemann geometrisi ilkeleriyle birleştirilerek "lognormal p-metriği" olarak adlandırılan yeni bir geometrik ölçüm mekanizması tanımlanmıştır. Geliştirilen metrik, hedef pikseller ile arka plan arasındaki parametrik mesafeyi ve kontrastı optimize ederek gemi yapılarının ayırt edilebilirliğini arttırmayı amaçlamaktadır.

Önerilen yöntemin sonuçlarına bakıldığında genellikle daha az yanlış alarm ve daha az kaçırılan hedef olduğu görülmektedir. Bu da yöntemin hem hassasiyet (precision) hem de yakalama oranı (recall) açısından daha dengeli olduğunu gösterir. Özellikle yoğun gemi trafiği olan sahnelerde hedeflerin birbirine yakın olması, tespit problemini zorlaştırır. Bu gibi durumlarda daha gelişmiş istatistiksel ya da öğrenme tabanlı yöntemlerin, klasik yaklaşımlara göre daha iyi ayırım yapabildiği bu tür görseller üzerinden net biçimde analiz edilebilir.

4.4 Derin Öğrenme Modelleri ile Alınan Sonuçlar

Tezin bu bölümünde kıyaslama amacıyla eğitilip metrikleri alınan ve derin öğrenme tabanlı modellerden biri olan YOLOv26 ve YOLOv12 ile oluşturulan veri setindeki performansına değinilmiştir. Yolov26 için iyi modelin (best.pt) doğrulama kümesi üzerindeki performansı Çizelge 4.2'de özetlenmiştir.

Metrik	Tüm Sınıflar	Gemi	Kara
mAP@50	0.7167	0.596	0.835
mAP@50-95	0.5073	0.316	0.699
Precision	0.685	—	—
Recall	0.673	—	—
F1 (max)	0.68 (conf=0.256)	~0.58	~0.80

Çizelge 4.2: Yolov26 için elde edilen metrikler.

Kara sınıfı 0.835 mAP@50 ve 0.699 mAP@50-95 değerleri ile güçlü bir tespit performansı sergilemiştir. Confusion matrix analizinde Kara etiketlerinin %82'sinin doğru sınıflandırıldığı, yalnızca %18'inin kaçırıldığı gözlemlenmiştir.

Gemi sınıfı ise 0.596 mAP@50 ile kabul edilebilir bir tespit oranı gösterirken, mAP@50-95 değeri 0.316 ile düşük kalmıştır. Confusion matrix'e göre gerçek gemilerin %57'si doğru tespit edilmiş, %43'ü ise background olarak sınıflandırılarak kaçırılmıştır.

Eğitim eğrileri incelendiğinde, hem eğitim hem doğrulama kayıplarının (box_loss, cls_loss, dfl_loss) sürekli düşüş eğiliminde olduğu görülmüştür. mAP@50-95 değeri ilk epoch'taki 0.338'den son epoch'taki 0.505'e yükselmiştir. Overfitting belirtisi gözlemlenmemiş; doğrulama kayıpları eğitim kayıplarıyla paralel seyretmiştir.

YoloV12 ile yapılan eğitim sonucu ortaya çıkan modelin doğrulama kümesi üzerindeki performansı ise Çizelge 4.3'te özetlenmiştir.

Metrik	Tüm Sınıflar	Gemi	Kara
mAP@50	0.632	0.632	0.784
mAP@50-95	0.298	0.297	0.702
Precision	0.695	—	—
Recall	0.601	—	—
F1 (max)	0.645	~0.60	~0.79


Çizelge 4.3: Yolov12 için elde edilen metrikler

İki modelde de gemi sınıfının mAP@50-95 metriğinin matematiksel modele göre daha düşük düzeyde kalmasının birden fazla yapısal nedeni bulunmaktadır.

SAR görüntülerindeki gemiler tipik olarak **3–10 piksel** genişliğinde tespit edilmektedir (800×800 piksel görüntüde normalize boyut ~0.004–0.012). Bu boyut, COCO verisetinde "küçük nesne" olarak tanımlanan 32×32 piksel eşiğinin çok altındadır. mAP@50-95 metriği, IoU eşiğini 0.50'den 0.95'e kadar artırarak hesaplandığından, küçük nesnelerde 1–2 piksellik bounding box kayması bile yüksek IoU eşiklerinde başarısız eşleşmeye yol açmaktadır. Bu durum, mAP@50 (0.596) ile mAP@50-95 (0.316) arasındaki belirgin farkı açıklamaktadır. Model gemileri tespit etmekte (mAP@50), ancak bounding box lokalizasyonunu yeterli hassasiyette gerçekleştirememektedir (mAP@50-95).

SAR görüntülerinin doğasında bulunan **speckle gürültüsü**, su yüzeyinde rastgele dağılan yüksek geri saçılım noktaları oluşturmaktadır. Bu noktalar, model tarafından gemi sinyalleriyle karıştırılmaktadır. Normalize confusion matrix, arka plan bölgelerinin %91 oranında Gemi olarak sınıflandırıldığını ortaya koymaktadır. Bu yüksek yanlış pozitif oranı, SAR görüntülerinin elektromanyetik geri saçılım tabanlı yapısından kaynaklanmakta olup, optik görüntülerde bu denli yoğun bir sorun gözlemlenmemektedir.


Şekil 4.3'de ilk satırda YOLOV26 ile elde edilen sınıflandırılmış örnek test görüntüleri yer alırken, ikinci satırda YOLOV12 ile elde edilmiş görüntüler bulunmaktadır.



Şekil 4.3: YOLO modellerinin tespit ettiği gemiler.

Daha güncel model olan v26 versiyonunun nispeten daha etkin bir şekilde nesne tespiti yapabildiği görülmüştür. Bu çalışmanın önceki bölümlerinde bahse konu olan sentetik açıklıklı radar görüntülerinin yapısından kaynaklı zorluklar, derin öğrenme modelleri için günümüzde hala zorlu bir koşuldur.

Derin öğrenme modelleri büyük görüntülerdeki küçük pikselleri tespit etmekte genellikle zorlanır. Yapısı gereği eğitim esnasında daha büyük piksel yoğunluğuna sahip nesnelere daha fazla dikkat ağırlığı verme eğilimindedirler. YOLOv26 ve YOLOv12 ile elde edilen sonuçlar da bunu doğrulamaktadır. Aşağıda şekil 4.4'te modelin tespit ettiği 4 doğrulama görüntüsüne yer verilmiştir. Açık denizde resimlerden de anlaşılacağı üzere gemi tespit oranları daha yüksekken kıyı, boğaz gibi sahne yoğunluğu fazla olan görüntülerde küçük gemileri gözden kaçırabildiği görülmektedir. Düşük piksel yoğunlukları eğitim sırasında modelin katsayılarına daha düşük etki ederken, daha büyük piksel yoğunluğuna sahip nesneler modelin eğitimindeki katsayılarla daha fazla etki etmekte ve modelin doğruluğunu arttırmaktadır.



Şekil 4.4: Yolov26'ın ürettiği doğrulama görüntüsü.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında ilk olarak SAR gemi görüntülerinin olduğu yeni bir görüntü veri tabanı inşa edilmiştir. Bu veri tabanındaki görüntüler gemi içerip içermediklerine göre uzman bir bakış açısı ile ayırt edilerek farklı klasörlere ayrılmıştır. Görüntüler dünyanın farklı kanal, liman, deniz ve okyanus bölgelerinden alınmıştır. Böylece sadece deniz, deniz/kara ve gemi/resif gibi çeşitli bilgiler içeren kapsayıcı bir veri tabanı oluşturulması sağlanmıştır.

Oluşturulan SAR gemi veri tabanı kullanılarak görüntülerde gemi olup olmadığının belirlenmesine yönelik iki farklı yöntem kullanılmıştır. İlk yöntemde derin öğrenme tabanlı bir yaklaşım kullanılmıştır. İkinci ve önerilen yöntemde ise Gauss fonksiyonu, Hessian matrisi ve özdeğer analizi yaklaşımlarından yararlanılmıştır. Gauss fonksiyonu yeni bir çerçevede ele alınarak SAR görüntülerinde olasılıksal kara/deniz ayırımına yönelik özgün bir metodoloji geliştirilmiştir. Bu yaklaşım yalnızca deniz bölgelerine odaklanmakta ve gemi tespiti için arama uzayını etkin biçimde daraltmaktadır. Gemilerin arka plandan ve resif gibi gemi benzeri yapılardan ayırt edilmesi amacıyla diferansiyel analiz teknikleri kullanılmıştır. Hessian matrisinin özdeğerleri, görüntünün içsel doku ve piksel bilgisini kodlamak için kullanılmış; az sayıda parlak piksele sahip gemiler, arka plandan ve benzer nesnelerden ayrı olarak tanımlanmıştır. Bilinen gemi tespit yöntemleriyle gerçekleştirilen karşılaştırmalı değerlendirmeler, önerilen yaklaşımın üstün bir tespit performansı sergilediğini ortaya koymaktadır.

Tez çalışmasında derin öğrenme modeli olan YOLO ile de veri tabanı üzerinde deneysel çalışmalar yapılmıştır. Kabul edilebilir gemi tespit sonuçları elde edilmiştir. Derin öğrenme tabanlı yöntemler yüksek doğruluk oranları sunmakla birlikte, SAR görüntülerinden gemi tespiti gibi kritik uygulamalarda beraberinde önemli kısıtlamalar getirmektedir. Bu modeller, performanslarını sürdürebilmek için büyük ölçekli etiketli veri kümelerine ihtiyaç duymakta; SAR verisi için bu tür veri kümelerinin oluşturulması ise hem maliyetli hem de zaman alıcı bir süreç gerektirmektedir. Bununla birlikte kullanılan veri tabanında makul gemi tespit sonuçları elde edilmiştir.

Önerilen yöntemde kullanılan Gauss fonksiyonu, Hessian matrisi ve özdeğer analizi gibi matematiksel modeller deterministik bir yapıya sahip olduğundan, aynı girdi koşulları altında her zaman aynı çıktıyı üretmekte ve sürecin her adımı matematiksel olarak izlenebilmektedir. Bu şeffaflık, söz konusu yöntemleri yüksek güvenilirlik gerektiren sistemlere entegrasyon açısından derin öğrenme alternatiflerine kıyasla belirgin biçimde daha uygun kılmaktadır. Nitekim bu çalışmada elde edilen sonuçlar, matematiksel temelli yaklaşımların karmaşık veri gereksinimlerine ya da yorumlanamayan model yapılarına başvurmaksızın rekabetçi ve hatta üstün tespit performansı sunabildiğini açıkça göstermektedir.



KAYNAKLAR

- [1] Copernicus Browser. (n.d.). Retrieved February 15, 2026, from <https://browser.dataspace.copernicus.eu/>
- [2] **Zhang, X., Feng, S., Zhao, C., Sun, Z., Zhang, S., & Ji, K.** (2024). MGSFA-Net: Multiscale Global Scattering Feature Association Network for SAR Ship Target Recognition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 4611–4625. <https://doi.org/10.1109/JSTARS.2024.3357171>
- [3] **Ma, W., Yang, X., Zhu, H., Wang, X., Yi, X., Wu, Y., ... Jiao, L.** (2024). NRENet: Neighborhood removal-and-emphasis network for ship detection in SAR Images. *International Journal of Applied Earth Observation and Geoinformation*, 131, 103927. <https://doi.org/10.3390/rs13183>
- [4] **Fan, X., Hu, Z., Zhao, Y., Chen, J., Wei, T., & Huang, Z.** (2024). A Small-Ship Object Detection Method for Satellite Remote Sensing Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 11886–11898. <https://doi.org/10.1109/JSTARS.2024.3419786>
- [5] **Xu, X., Zhang, X., & Zhang, T.** (2022). Lite-YOLOv5: A Lightweight Deep Learning Detector for On-Board Ship Detection in Large-Scene Sentinel-1 SAR Images. *Remote Sensing*, 14(4). <https://doi.org/10.3390/rs14041018>
- [6] **Yu, Y., Wang, B., & Zhang, L.** (2011). Hebbian-based neural networks for bottom-up visual attention and its applications to ship detection in SAR images. *Neurocomputing*, 74(11), 2008–2017. <https://doi.org/10.1016/j.neucom.2010.06.026>
- [7] **Yu, C., & Shin, Y.** (2024). An efficient YOLO for ship detection in SAR images via channel shuffled reparameterized convolution blocks and dynamic head. *ICT Express*, 10(3), 673–679. <https://doi.org/10.1016/j.ict.2024.02.007>
- [8] **Wei, S., Zeng, X., Qu, Q., Wang, M., Su, H., & Shi, J.** (2020). HRSID: A High-Resolution SAR Images Dataset for Ship Detection and Instance Segmentation. *IEEE Access*, 8, 120234–120254. <https://doi.org/10.1109/ACCESS.2020.3005861>
- [9] **Zhang, T., Zhang, X., Li, J., Xu, X., Wang, B., Zhan, X., ... Wei, S.** (2021). SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing 2021, Vol. 13*, 13(18). <https://doi.org/10.3390/rs13183690>
- [10] **Li, J., Qu, C., & Shao, J.** (2017). Ship detection in SAR images based on an improved faster R-CNN. *Proceedings of 2017 SAR in Big Data Era: Models, Methods and Applications, BIGSAR DATA 2017, 2017-January*, 1–6. <https://doi.org/10.1109/BIGSAR DATA.2017.8124934>
- [11] **Cui, Z., Li, Q., Cao, Z., & Liu, N.** (2019). Dense Attention Pyramid Networks for Multi-Scale Ship Detection in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11), 8983–8997. <https://doi.org/10.1109/TGRS.2019.2923988>
- [12] **Fu, J., Sun, X., Wang, Z., & Fu, K.** (2021). An Anchor-Free Method Based on Feature Balancing and Refinement Network for Multiscale Ship Detection in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 59(2), 1331–1344. <https://doi.org/10.1109/TGRS.2020.3005151>
- [13] **Zhang, Y., Han, D., & Chen, P.** (2023). Swin-PAFF: A SAR Ship Detection Network with Contextual Cross-Information Fusion. *Computers, Materials and Continua*, 77, 2657–2675. <https://doi.org/10.32604/cmc.2023.042311>
- [14] **Redmon, J. S. D. R. G. A. F.** (2016). (YOLO) You Only Look Once. *Cvpr, 2016-December*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>

- [15] **Ren, S., He, K., Girshick, R., & Sun, J.** (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- [16] **Girshick, R.** (2015). Fast R-CNN. In *2015 IEEE International Conference on Computer Vision (ICCV)* (pp. 1440–1448). IEEE. <https://doi.org/10.1109/ICCV.2015.169>
- [17] **He, K., Gkioxari, G., Dollar, P., & Girshick, R.** (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision, 2017-October*, 2980–2988. <https://doi.org/10.1109/ICCV.2017.322>
- [18] **Taha Burak ÖZDEMİR.** (2024, July). *MAKİNE ÖĞRENMESİ VE GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE SAR GÖRÜNTÜLERİNDE GEMİ TESPİTİ*. İnönü Üniversitesi, Malatya.
- [19] **Leng, X., Ji, K., Yang, K., & Zou, H.** (2015). A Bilateral CFAR Algorithm for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*, 12(7), 1536–1540. <https://doi.org/10.1109/LGRS.2015.2412174>
- [20] **Xie, Z., Cheng, Y., Wu, H., Zhang, L., & Wang, H.** (2022). Ship Target Detection in SAR Imagery Based on Maximum Eigenvalue Detector. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2022.3204907>
- [21] **Erçelik, Ç., Hanbay, K., & Özbek, H. C.** (2025). Ship Detection in SAR Images Using CLAHE-Enhanced YOLOv8x. *9th International Artificial Intelligence and Data Processing Symposium, IDAP 2025*. <https://doi.org/10.1109/IDAP68205.2025.11222185>
- [22] **Hanbay, K., Uzen, H., Ozdemir, T. B., & Ercelik, C.** (2024). Noise Reduced SAR Ship Database. *8th International Artificial Intelligence and Data Processing Symposium, IDAP 2024*. <https://doi.org/10.1109/IDAP64064.2024.10710785>
- [23] **Hanbay, K.** (2025). SAR Ship Detection Based on Gaussian Probability and Eigenvalue Analysis. *IEEE Signal Processing Letters*, 32, 2214–2218. <https://doi.org/10.1109/LSP.2025.3571640>
- [24] **Wang, Y., Wang, C., Zhang, H., Dong, Y., & Wei, S.** (2019). A SAR Dataset of Ship Detection for Deep Learning under Complex Backgrounds. *Remote Sensing 2019, Vol. 11, 11(7)*. <https://doi.org/10.3390/rs11070765>
- [25] **Wei, S., Zeng, X., Qu, Q., Wang, M., Su, H., & Shi, J.** (2020). HRSID: A High-Resolution SAR Images Dataset for Ship Detection and Instance Segmentation. *IEEE Access*, 8, 120234–120254. <https://doi.org/10.1109/ACCESS.2020.3005861>
- [26] **Zhang, T., Zhang, X., Ke, X., Zhan, X., Shi, J., Wei, S., ... Kumar, D.** (2020). LS-SSDD-v1.0: A Deep Learning Dataset Dedicated to Small Ship Detection from Large-Scale Sentinel-1 SAR Images. *Remote Sensing 2020, Vol. 12, 12(18)*. <https://doi.org/10.3390/RS12182997>
- [27] **Zhang, T., Zhang, X., Li, J., Xu, X., Wang, B., Zhan, X., ... Wei, S.** (2021). SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis. *Remote Sensing 2021, Vol. 13, 13(18)*. <https://doi.org/10.3390/rs13183690>
- [28] **Lei, S., Lu, D., Qiu, X., & Ding, C.** (2021). SRSDD-v1.0: A High-Resolution SAR Rotation Ship Detection Dataset. *Remote Sensing 2021, Vol. 13, 13(24)*. <https://doi.org/10.3390/rs13245104>
- [29] **Rouault, E., Warmerdam, F., Schwehr, K., Kiselev, A., Butler, H., Łoskot, M., ... Miura, H.** (n.d.). GDAL. <https://doi.org/10.5281/ZENODO.18558562>
- [30] **Hanbay, K., Alpaslan, N., Talu, M. F., Hanbay, D., Karci, A., & Kocamaz, A. F.** (2015). Continuous rotation invariant features for gradient-based texture

- classification. *Computer Vision and Image Understanding*, 132, 87–101. <https://doi.org/10.1016/j.cviu.2014.10.004>
- [31] GitHub - ultralytics/ultralytics: Ultralytics YOLO 🚀 · GitHub. (n.d.). Retrieved March 28, 2026, from <https://github.com/ultralytics/ultralytics>
- [32] **Tian, Y., Ye, Q., & Doermann, D.** (n.d.). YOLOv12: Attention-Centric Real-Time Object Detectors Latency (ms) MS COCO mAP (%). *arXiv preprint arXiv:2502.12524*. <https://doi.org/10.0>
- [33] **Pappas, O., Achim, A., & Bull, D.** (2018). Superpixel-level CFAR detectors for ship detection in SAR imagery. *IEEE Geoscience and Remote Sensing Letters*, 15(9), 1397–1401. <https://doi.org/10.1109/LGRS.2018.2838263>
- [34] **Yang, M., & Guo, C.** (2018). Ship Detection in SAR Images Based on Lognormal ρ - Metric. *IEEE Geoscience and Remote Sensing Letters*, 15(9), 1372–1376. <https://doi.org/10.1109/LGRS.2018.2838043>



ÖZGEÇMİŞ

Ad-Soyad: Hasan Can ÖZBEK

ÖĞRENİM DURUMU:

Lisans: 2020-2024, İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

MESLEKİ DENEYİM

- Ekim 2022 – Kasım 2023 yarı zamanlı olarak Teknokent bünyesinde faaliyet gösteren Runibex firmasında yazılım geliştirici olarak çalışmıştır. Vestel, Regal gibi dayanıklı elektronik eşya üretimi yapan firmaların e-ticaret altyapısında geliştirmeler yapmıştır.
- Haziran - Ağustos 2025 dönemi arasında, yine Teknokent bünyesinde faaliyet gösteren Ayssoft firmasında .Net Geliştirici pozisyonunda e-fatura alanında çalışmıştır.
- Ağustos 2025'ten beri Türk Havacılık ve Uzay Sanayii - Aviyonik Yazılım biriminde mühendis olarak çalışmaktadır.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN ÇALIŞMALAR

- **Ç. Erçelik, K. Hanbay, H. C. Özbek.** (2025). Ship Detection in SAR Images Using CLAHE-Enhanced YOLOv8x. 9th International Artificial Intelligence and Data Processing Symposium (IDAP), Malatya, Türkiye, 2025, pp. 1-5, doi: 10.1109/IDAP68205.2025.11222185.