

**T.C.
MİLLÎ SAVUNMA ÜNİVERSİTESİ
BARBAROS DENİZ BİLİMLERİ VE MÜHENDİSLİĞİ
ENSTİTÜSÜ
DENİZ ELEKTRONİK SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI
ELEKTRONİK SİSTEMLERİ MÜHENDİSLİĞİ YÜKSEK
LİSANS PROGRAMI**

**OTOMATİK SAVAŞ GEMİSİ
SINIFLANDIRMA
YÜKSEK LİSANS TEZİ**

**YAVUZ ALPER KARA
17100101**

TEZ DANIŞMANI: DR.ÖĞR. ÜYESİ BATUHAN GÜNDOĞDU

**İSTANBUL
OCAK 2020**

**T.C.
MİLLÎ SAVUNMA ÜNİVERSİTESİ
BARBAROS DENİZ BİLİMLERİ VE MÜHENDİSLİĞİ
ENSTİTÜSÜ
DENİZ ELEKTRONİK SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI
ELEKTRONİK SİSTEMLERİ MÜHENDİSLİĞİ YÜKSEK
LİSANS PROGRAMI**

**OTOMATİK SAVAŞ GEMİSİ
SINIFLANDIRMA
YÜKSEK LİSANS TEZİ**

**YAVUZ ALPER KARA
17100101**

**Tezin Enstitüye Verildiği Tarih: 07 Ocak 2020
Tezin Savunulduğu Tarih: 10 Ocak 2020**

Tez Oy birliği / Oy çokluğu ile başarılı bulunmuştur.

**Tez Danışmanı : Dr.Öğr.Üyesi Batuhan GÜNDOĞDU
Jüri Üyeleri : Prof.Dr. Nafiz ARICA
Dr.Öğ.Üyesi Deniz KUMLU**

**İSTANBUL
OCAK 2020**

ÖZGÜNLÜK RAPORU

Tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve ç) Sonuç kısımlarından oluşan toplam 52 sayfalık kısmına ilişkin, 15/12/2019 tarihinde şahsım tarafından turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan özgünlük raporuna göre, tezimin benzerlik oranı % 2'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Millî Savunma Üniversitesi Barbaros Deniz Bilimleri ve Mühendisliği Enstitüsü Lisansüstü Tez Çalışması Özgünlük Raporu Alınması ve Kullanılması Uygulama Usul ve Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Yavuz Alper KARA

10 Ocak 2020

ETİK BEYANI

Millî Savunma Üniversitesi Enstitüleri Lisansüstü Tez Hazırlama Kılavuzu'nda yer alan kurallarına uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir; aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Bu tezdeki düşünce, görüş, varsayım, sav veya tezler bana aittir; Millî Savunma Bakanlığı, Türk Silahlı Kuvvetleri, Deniz Kuvvetleri Komutanlığı, Millî Savunma Üniversitesi ve Barbaros Deniz Bilimleri ve Mühendisliği Enstitüsü sorumlu tutulamaz.

Yavuz Alper KARA
10 Ocak 2020

ÖNSÖZ ve TEŞEKKÜR

Akademik hayata atıldığım ilk günden başlayarak bilgisi ve heyecanı ile beni sürekli destekleyen, yardımlarını hiçbir zaman esirgemeyen, karşılaştığım tüm sorunlarda zaman ve yer mefhumu gözetmeksizin her an yanımda olan çok değerli danışman hocam Dr.Öğr.Üyesi Batuhan GÜNDOĞDU'ya sağladığı tüm destek için sükranlarımı sunarım.

Ayrıca,

Tez Savunma Jüri Üyeleri Prof. Dr. Nafiz ARICA ve Dr. Öğr.Üyesi Deniz KUMLU'ya

Yüksek lisans eğitimime başlamamda büyük teşviği ve katkısı olan, beni heyecanla destekleyen Dr.Öğr.Üyesi Doğuş ÖZKAN'a,

Özellikle eğitimimin ilk yılında derslere katılma konusunda yardımlarını esirgemeyen değerli büyüğüm Emin YILMAZ'a

Şehadetiyle bayrağımıza renk üniformama şan ve şeref katan babam Şehit Hv.Pl. Yzb. Faruk KARA'ya,

Bana her koşulda güvenen ve beni destekleyen sevgili anneme ve abime,

Her zaman olduğu gibi bu süreçte de her türlü desteği sonuna kadar veren çok değerli eşim Selma KARA'ya,

Son olarak yaktığı meşale ile en büyük eğitimci, en büyük yol gösterici ve ilham kaynağım olan Gazi Mustafa Kemal ATATÜRK'e

Gönülden teşekkür ederim...

İstanbul; Ocak 2020

Yavuz Alper KARA

İÇİNDEKİLER

	Sayfa
ÖZGÜNLÜK RAPORU	
ETİK BEYANI	
TEŞEKKÜR VE ÖNSÖZ	
İÇİNDEKİLER	vi
TABLolar LİSTESİ	vii
ŞEKİLLER LİSTESİ	vii
SEMBOL LİSTESİ	ix
KISALTMALAR	x
TÜRKÇE ÖZ	xi
İNGİLİZCE ÖZ (ABSTRACT)	xii
1. GİRİŞ	1
2. METODOLOJİ	6
2.1. Veri Seti	6
2.1.1. Veri Madenciliği	9
2.2. Veri Önışleme	10
2.2.1. Ön Filtreleme	12
2.3. Öznitelik Çıkarımı	19
2.3.1. Gradyan Yönelimlerinin Histogramı (HOG-Histogram of Oriented Gradients)	19
2.3.2. Yerel İkili Örüntü (LBP-Local Binary Pattern)	21
2.4. Normalizasyon	27
2.5. Dekorelasyon ve Boyut Azaltma	29
2.6. Füzyon	30
2.7. Sınıflandırma	33
2.8. Veri Artırma	35
3. DENEYLER	37
4. TARTIŞMA VE SONUÇ	51
4.1. Veri Setinin Katkıları	51
4.2. Füzyonun Katkıları	51
4.3. Veri Artırmanın Katkıları	51
4.4. Sonuçlar	52
4.5. Tartışma ve Öneriler.....	52
KAYNAKÇA	
ÖZGEÇMİŞ	

TABLolar LİSTESİ

	Sayfa
Tablo 2.1: Türk Deniz Kuvvetleri Envanterinde Bulunan Gemi Tipleri	6
Tablo 2.2: Gauss Filtresi Çekirdeđi Hesaplama Tablosu	18
Tablo 3.1: Filtre Uygulamalarının Veri Seti Üzerindeki Etkileri	37
Tablo 3.2: TPLBP ve FPLBP Deney Sonuçları	44
Tablo 3.3: C ve Gama Parametrelerinin Veri Seti Üzerindeki Etkileri	47
Tablo 3.4: İki Basamaklı Füzyon Uygulanması Sonucu Elde Edilen Veriler	48
Tablo 3.5: TPLBP ve FPLBP Algoritmalarının LP ve HP Filtre ile İki Basamaklı Füzyon Uygulaması Sonuçları	49

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1: Otomatik Savaş Gemisi Sınıflandırma Akış Diyagramı	6
Şekil 2.2: Değerlendirme Dışı Tutulan İmge Örnekleri	10
Şekil 2.3: Veri Seti Boyutu ve Dağılımı.....	10
Şekil 2.4: Veri Önışleme Akış Diyagramı.....	11
Şekil 2.5: Önışleme Öncesi ve Sonrası İmge Örneđi	12
Şekil 2.6: Filtre Uygulanmamış Gemi İmgesi	13
Şekil 2.7: Alçak Geçirgen (Low Pass) Filtre Uygulamaları	13
Şekil 2.8: Yüksek Geçirgen (High Pass) Filtre Uygulamaları.....	13
Şekil 2.9: Roberts Çekirdeđi.....	14
Şekil 2.10: Sobel Çekirdeđi	15
Şekil 2.11: Scharr Çekirdeđi.....	15
Şekil 2.12: Sobel ve Scharr Filtrelerinin karşılaştırması	15
Şekil 2.13: İmge üzerine uygulanan Gauss Filtresinin Örnekleme	17
Şekil 2.14: Gauss Filtresi Uygulanması Sonucu Elde Edilen Deđerler.....	17
Şekil 2.15: Gauss Çekirdeđi	18
Şekil 2.16: Önışleme Yapılmış Gemi İmgesinde HOG Özniteliklerinin Görseli (Blok Boyutu 4x4, Hücre Boyutu 32x32 Alınmıştır.)....	20
Şekil 2.17: HOG Özniteliklerinin Boyutunun Açıklanması	20
Şekil 2.18: LBP Hesaplama Modelleri	21
Şekil 2.19: LBP Uniform Geçiş Deđerleri.....	22
Şekil 2.20: P=8, R=1 için Örnek LBP Hesaplama Modeli.....	23
Şekil 2.21: TCG BÜYÜKADA'ya Ait LBP İşleme Örneđi.....	24
Şekil 2.22: TPLBP Hesaplama Modeli (S=8, w=3,α=2).....	25
Şekil 2.23: LBP ve CSLBP Hesaplama Modeli	26
Şekil 2.24: FPLBP Hesaplama Modeli	26
Şekil 2.25: ADA Sınıfı Korvete Ait Örnek İmge	28

Şekil 2.26: x, y Koordinat Düzleminden PC Koordinat Düzlemine Geçiş ...	30
Şekil 2.27: İki Basamaklı Olarak Uygulanan Füzyon İşlemi	31
Şekil 2.28: TPLBP-FPLBP İki Basamaklı Füzyon İşlem Basamakları.....	32
Şekil 2.29: Destek Vektör Makinesi, Marjin ve Destek Vektörleri.....	33
Şekil 2.30: RBF Temelli Sınıflandırıcı Uygulaması	34
Şekil 2.31: TCG KUMKALE(P-1203)'ye Ait Veri Arttırma İşlemi Sonucu Elde Edilen İmgeler	35



KISALTMALAR

HOG	: Histogram of Oriented Gradients
SVM	: Support Vector Machine
LBP	: Local Binary Pattern
TPLBP	: Three Patch Local Binary Pattern
FPLBP	: Four Patch Local Binary Pattern
CSLBP	: Center-Symmetric Local Binary Pattern
PCA	: Principal Component Analysis
PC	: Principle Component
RGB	: Red Green Blue
HP	: High Pass
LP	: Low Pass
LHP	: Low-High Pass
RBF	: Radial Basis Function
ATR	: Automatic Target Recognition
FLIR	: Forward Looking Infrared Radar
SAR	: Synthetic Aperture RADAR
EMG	: Elektromyografi
TCG	: Türkiye Cumhuriyeti Gemisi
MİLGEM	: Milli Gemi
YTKG	: Yeni Tip Karakol Gemisi
TDR	: Tanımlanmış Deniz Resmi

SEMBOL LİSTESİ

γ	: SVM parametresi
C	: SVM parametresi
σ	: Bulanıklaştırma düzeyi
Θ	: Füzyon işlemi
τ	: 0,001
α	: TPLBP/FPLBP bloklar arası mesafe
μ	: Ortalama
χ	: Vektörler
x	: Vektör
\mathcal{R}	: Reel Sayılar

ÖZ

Otomatik Savaş Gemisi Sınıflandırma

Yavuz Alper KARA

Millî Savunma Üniversitesi, Barbaros Deniz Bilimleri ve
Mühendisliği Enstitüsü
İstanbul, Ocak 2020

Tanımlanmış Deniz Resminin oluşturulması ve idamesi için gerekli olan gemi tiplerinin sınıflandırılması, özellikle kriz ve bilhassa savaş dönemlerinde hayati önem arz etmektedir. Sivil ticari deniz araçlarının sınıflandırılmasına yönelik literatürde birçok çalışma mevcuttur. Bununla birlikte gerek boyut ve gerekse de şekil itibariyle birbirlerine çok benzeyen savaş gemilerinin yalnızca tip olarak değil sınıf bazında da sınıflandırılmalarını hedefleyen çalışmalar hali hazırda olgunluktan uzaktır. Bu çalışmada çeşitli savaş gemilerinin optik kameralar aracılığıyla elde edilen imgelerini, imge işleme ve yapay öğrenme teknikleri kullanılarak yalnızca tip bazında yetinilmeyip sınıf bazında da otomatik olarak sınıflandırılmasını araştıran bir sistem sunulmaktadır. Çalışmada, gemi imgelerinden Gradyan Yönelimlerinin Histogramı ve Yerel İkili Örüntü aracılığıyla elde edilen öznitelik vektörleri çeşitli önışlemelerden geçirildikten sonra Destek Vektör Makineleri ile sınıflandırılması incelenmiştir. Türk donanması envanterinde bulunan görsel açıdan birbirlerine benzeyen 9 savaş gemisi sınıfına ait farklı açı, mesafe ve arka plan özelliklerine sahip gemi imgeleriyle bir veri seti oluşturulmuş ve yapılan deneylerin sonucunda önerilen yaklaşımın %86'lık bir validasyon başarımına ulaştığı görülmüştür.

Anahtar Sözcükler : Gradyan Yönelimlerinin Histogramı, İkili Yerel Örüntü, Öznitelik Çıkarımı, Veri artırma, Füzyon.

Bilim Kodu : 90541
Sayfa Sayısı : 52
Tez Danışmanı : Dr.Öğr.Üyesi Batuhan GÜNDOĞDU

ABSTRACT

Automatic Warship Classification

Yavuz Alper KARA

Turkish National Defense University, Barbaros Naval Sciences and
Engineering Institute

Istanbul, January 2020

It's crucial that classification of ships which are necessary according to procure and sustain of Recognition Maritime Picture (RMT) during the crises and especially in war times. There are many studies in literature intended for civilian commercial maritime vessels. In addition, recently, the studies aim to classify the warships, similar in both shape and size, not only in types but also in classes are far from maturity. In this study a system is proposed by using image processing and machine learning which is seek for automatic classification for images, that are obtained from optical sensors, belongs to various warships. In the study, the classification of feature extraction, after diverse preprocessing, attained by Histogram of Oriented Gradients and Local Binary Patterns by Support Vector Machine is investigated. A dataset is composed based on images that have different aspects, distances and background features of particularly similar 9 warship classes that exist in the Turkish Navy and it has been shown that the proposed approach reaches 85% classification accuracy.

Keywords : HOG, LBP, Feature Extraction, Data
Augmentation, Fusion.

Science Code : 90541

Pages : 52

Supervisor : Assistant Professor Batuhan GÜNDOĞDU, PhD

1. GİRİŞ

Kahvesinden bir yudum aldıktan sonra Duru, Ece'ye dönerek merakla sordu: “Bu durumda ne yapmamı önerirsin?” Ece, Duru'nun omuzları düşük, başı yerde haline üzülüyor ve onu böyle görmek istemiyordu. “Şüphesiz onu benden çok daha iyi tanıyorsun. Onun yaşamını göz önüne getirmeni istiyorum; isteklerini, umutlarını, fantezilerini, başarılarını ve belki de en önemlisi yapmak isteyip yapamadıklarını.” Buğulu gözlerle bakmaya devam ederken Duru, Ece konuşmasına devam etti. “Biliyorsun ki onun en büyük arzusu insanlara yardım etmektir. Tüm çalışmaları, tüm yazıları ve hatta tüm eleştirileri bile bu yöndeydi. Dolayısıyla son bir iyilik yapmak bence onun en büyük hakkı ve elbette en büyük isteği olacaktır. Konuya bu açıdan yaklaşırsan gereksiz düşüncelerden kurtulabileceğine ve en güzel kararı verebileceğine inanıyorum. Bu kararı verdikten sonra da rahatlayacak ve kendini kuş gibi hissedeceksin. Sevdiğin birini kaybetmenin ne demek olduğunu senin kadar olmasa da ben de hissediyorum. Onun organlarını bağışlayarak kaç kişiye umut olacağını, kaç kişinin ve ailesinin gözünde bir ışık hatta bir kıvılcım olacağını düşün. Belki eşinin yapmak istediklerini, yeni bir yaşam sansı tanıdığı o insanlar yapacak. Ne dersin?”

“Sana çok ama çok teşekkür ederim Ece. Beni her zamanki gibi en iyi anlayan sensin ve şu an sayende gerçekten hafifledim.”

Tüm bu konuşmanın Duru ile Duyuşsal Yapay Zeka Ece arasında geçtiği günler bir çok bilim insanı için çok da uzak bir olasılık değil (Picard, 1997), (Minsky, 2007).

Yapay zeka kavramı ilk olarak John Mccarty tarafından Dartmouth'ta düzenlenen bir konferansta terimleştirilmiş olsa da Alan Turing'in 1950 yılında Turing Testi (imitation game)(Turing A., 1950) deneyini ortaya koymasıyla konunun fitili ateşlenmiştir. Turing'in 1950 yılında yayınladığı bu çalışmasıyla birlikte günümüzde de yoğun bir şekilde sorulan ve hatta neredeyse “er ya da geç olacak” gözüyle bakılan çok önemli bir soruyu gündeme getirmiştir: Makineler düşünebilir mi?

Geleneksel olarak bilgisayarlar iki rakamı toplamaktan bir uçağı uçurmaya veya indirmeye kadar herhangi bir şeyi yapmasının tek yolu, en küçük ayrıntıları da içerecek şekilde yazılan bir algoritma kullanmasıdır. Fakat yapay zeka bundan çok daha farklıdır. İki imgeyi karşılaştırarak bunların aynı kişinin yüzü olduğuna karar verilmesi için kişinin yüzünü tanımlayan bir algoritma yazılamaz, en azından şimdiye kadar yazılamadı. Bununla birlikte bir kişiye ait onlarca sayıda (son çalışmalar tek bir resimle yapılabilmesine yönelik) yüz imgesinin varlığı sayesinde böylesine zorlu bir algoritma yazma çabalarına gerek kalmamıştır. Elimizde var olan bu onlarca ya da tek bir yüz imgesiyle bir makineyi eğiterek karşımıza gelen imgenin aynı kişiye ait olup olmadığını kolayca bulabiliriz. Burada programcı yalnızca makinenin nasıl eğitileceğine karar vermektedir. İmgeyi gören ve sınıflandırma işlemini yapan artık bilgisayardır. Bir başka deyişle yapay zekada algoritma yazmaktan farklı olan kısım eğitici programı programlamaktır; işin geri kalan kısmını program kendi başına yapabilmektedir.

Yaklaşık 65 yıl önce başlayan yapay zekaya yönelik çalışmalar gün geçtikçe hız kazanmış ve hatta bazı alanlarda insanların önüne geçmeyi başarmıştır. Örneğin eğitilmiş kulaklarla bile keman ve viyolanın seslerinin ayırımını yapabilmek kolay değilken sıradan insanların tüm notalarda bunları yüksek başarıyla sınıflandırabilmesi çok güçtür. Yapay zeka ile bu başarı %80'ler civarında yapılabilmektedir (Avcı, 2018). Bunun yanı sıra elektrotlar aracılığıyla elde edilen ve Elektromyografi (EMG) adı verilen elektriksel işaretlerin sınıflandırılması ile engelli kişilerin tekerlekli sandalyelerini kontrol edebilmesinin önü açılmıştır (Çerçi, 2018). Kuşkusuz yapay zeka yalnızca elektrik sinyalleri ve ses dalgalarının sınıflandırılmasında kullanılmamaktadır. Palabaş ve Erkaymaz tarafından yapılan bir çalışmada (Palabaş, 2018) Tanı ve tedaviye hız kazandırmak ve doğru karar vermeye yardımcı olmak amacı ile Serviks kanseri verilerinin sınıflandırılması üzerine çalışılmış ve %95,51'lik bir sınıflandırma başarısına ulaşılmıştır. Kanser üzerine yapılan çalışmalar Kourou ve diğ. tarafından bir araya getirilmiştir. Çalışmada net bir şekilde görülmektedir ki birçok kanser çeşidi %90'ın üzerinde doğruluk ile tanımlanmış ve sınıflandırılmıştır (Kourou, 2015). Yapay zeka, makine öğrenmesi ve imge işleme denince akla ilk gelen konulardan birisi kuşkusuz yüz tanıma sistemi olmuştur. Günümüzde bilgisayarlardan, cep telefonlarına ve hatta birçok banka uygulamasına kadar çeşitli alanlarda verimli

bir şekilde kullanılan yüz tanıma sisteminin başarısının ardında yatan temel neden makine öğrenmesidir. Konu hakkında uzun yıllar çalışmalar yapılmış ve söz konusu çalışmalar günlük hayatımızın bir parçası haline gelmiş olsa da bu çalışmalar hala devam etmektedir. Yüz tanıma ile ilgili güncel çalışmaların yoğunlaştığı noktalardan birisi de tek bir resim ile yüksek sınıflandırma başarıları elde etmektir (Parkhi, 2015), (Schroff, 2015). Bununla birlikte akla ilk gelen bir başka konu ise sürücüsüz araçlar. Bu konuda uzun yıllardır yapılan yüzlerce çalışma yer almaktadır (Tian, 2018), (Zhang, 2018), (Dollar, 2011), (Dalal, 2005). Henüz sürücüsüz arabalar vazgeçilmezlerimiz arasına girmemiş olsalar da bu alanda yapılan çalışmalar sayesinde günlük hayatta kullanımı gün geçtikçe yaygınlaşan ve birçok arabanın standart donanımı haline gelen şerit takip ve sürücü ikaz sistemleri uygulamalarına başlanmıştır. Teknolojik gelişim denilince ülkelerin güvenlikleri elbette ticari konulardan çok daha hayati öneme sahiptir ve çalışmalar çok ciddi bütçelerle yapılabilmektedir. Birçok ülke makine öğrenmesinin ülke güvenliğine katkıları üzerinde yoğun çalışmalar yapmaktadır. Sınır güvenlikleri (Bhanu, 1986), (Mahfouz S., 2014) ve ülke içerisindeki ulusal güvenliği tehdit edebilecek yasa dışı ticaret trafiğinin izlenmesi (Gąszczak, 2011) gibi konular büyük önem arz etmektedir.

Kullanım alanları oldukça geniş olan imge işleme ve örüntü tanıma teknikleri deniz araçları gemi sınıflandırmada askeri ve ticari nedenlerden dolayı da oldukça gündemde olan bir konudur (Gündoğdu, 2016), (Solmaz, 2017), (Gürkaynak, 2018). Bilinmeyen temasların ticari ve askeri olarak sınıflandırılmaları ülke güvenliği ve yasa dışı göç açılardan büyük önem arz ederken yalnızca bu sınıflandırmalar son derece yetersiz kalmaktadır. Tanımlanmış Deniz Resminin (TDR) tam olarak oluşturulabilmesi, ticari temasların yanı sıra tespit edilen askeri temasların en azından tip bazında sınıflandırılmalarını da gerekli kılmaktadır. Askeri gemiler birçok farklı amaç için çeşitli özellikte üretilirler. Bu amaçlar yalnızca destek gemileri, akaryakıt gemileri ile açık denizler için üretilen büyük boyutlardaki savaş gemileri ve kıyı hatlarının savunulması amacıyla üretilen nispeten küçük boyutlardaki savaş gemileriyle sınırlı kalmaz. Her tipteki gemiler belli bir amacı karşılamaya yönelik olarak belli başlı sistem ve cihazları üzerlerinde barındırırlar. Bazı fırkateynler hava savunma harbine yönelik olarak kullanılırken bazı fırkateynler suüstü savunma harbine yönelik olarak kullanılırlar. Bu ayırım daha küçük boyutlardaki karakol gemileri ve hücumbotlar için

de geçerlidir. Bunların ayırımını başarılı bir şekilde yapabilmek TDR'ye büyük katkı sağlamakta ve özellikle kriz ve savaş zamanlarında hayati önem arz etmektedir.

Savaş gemisi sınıflandırmaya yönelik literatürde doğrudan aynı özellikte bir çalışma yer almasa da, bu tezde yer alan araştırmaya benzer çalışmalar bulunmaktadır. Chuaysi ve arkadaşları (Chuaysi, 2012) Jane's Fighting Ship (Saunders, 2011) ve Jane's Warship Recognition Guide (Watts, 2006)'dan elde ettikleri gemi silüetlerini ve bunların bilgisayar yardımı ile elde edilen farklı açılardaki yönelimleri ile bir çalışma gerçekleştirmişlerdir. Değerlendirmeye aldıkları sekiz sınıf üzerinde %79,41 ve %66,18'lik bir sınıflandırma başarısı elde etmişlerdir. Kumlu ve Jenkins (Kumlu, 2013)'in çalışmasında ise bilgisayar ortamında elde edilen sentetik verilerde eğitilen algoritma gerçek imgeler üzerinde test edilmiştir. Bu sayede %93.3'lük bir başarı elde edilmiştir. Otomatik Hedef Tanımlama (ATR-Aurtoautomatic Target Recognition) üzerine yaptığı çalışmada Alves (Alves, 2001) MATLAB ile oluşturulan 3B gemi silüetlerine ek olarak FLIR kamera ile elde edilmiş kızılötesi imgeler de kullanılmıştır. Hem eğitim setinde hem de test setinde kullanılan bu veri seti ile %94,8'lik bir doğruluk başarısı elde edilmiştir.

İmge işleme ile yapılan gemi sınıflandırmalarının büyük bir kısmını SAR ile elde edilen imgeler üzerinde yapılan çalışmalar oluşturmaktadır. Bu çalışmalar iki ayrı grupta incelenebilir. Birinci grup yaklaşık 2000'li yıllara kadar olan çalışmalardır (Musman, 1996), (Valin, 1999), (Osman, 1999). Bu zamana kadar eldeki verilerin azlığı ve verilere ulaşım zorlukları çalışmaları genelde bu alana yönlendirmiştir. 2000'li yıllarla birlikte kişisel bilgisayar ve fotoğraf makinelerinin kullanımının ciddi oranda artmasına ek olarak internette yaşanan gelişimler nedeniyle RGB imge işleme ile yapılan sınıflandırmalar büyük hız kazanmıştır. Her ne kadar açık kaynaklardan ulaşımı gibi rahat olmasa da sınırlı kullanıma sahip olsalar da 2007 yılında yörüngeye oturtulan hızlı ve yüksek çözünürlüklü veri gönderimine izin veren TerreSAR-X ve Radarsat-2 uydularının kullanıma başlanması ile birlikte SAR imgeleri yeniden çalışma alanının bir parçası olmuştur (Margarit, 2011), (Bentes, 2017), (Lang, 2014), (Lang H. Z., 2015).

Bu çalışmanın yukarıda söz edilen çalışmalardan temel farkları, gerek eğitim seti gerekse de test setinde 3B herhangi bir imgenin kullanılmaması, veri seti dahilinde doğruluk oranını arttıracakları düşünülen ticari gemiler, uçak gemileri ve denizaltı vb.

gemilerin kullanılmamasıdır. Veri seti açık kaynaklardan internet yoluyla elde edilen tamamen gerçek gemi imgelerine dayanmaktadır.

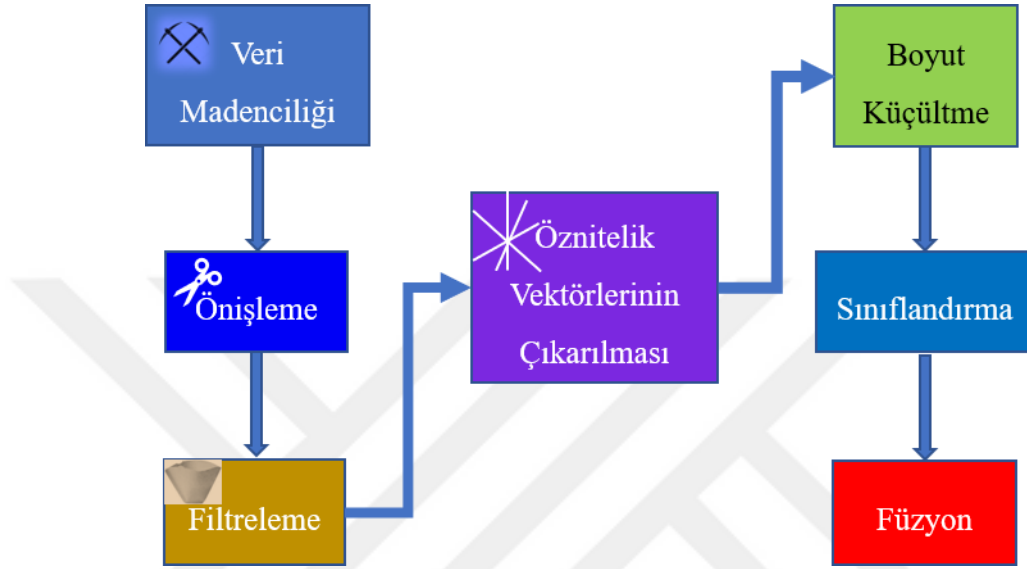
Bu çalışmanın özgün yanları:

1. Türk Donanmasındaki gemilere yönelik olarak açık kaynaklardan bir veri seti oluşturulmuş ve deneylerle incelenmiştir.
2. Gemi tanıma için HOG ve LBP gibi iki öznitelik çıkarma metodolojisinde en uygun parametrelerin belirlenmesi için bir deney tasarımı süreci gerçekleştirilmiştir.
3. Veri artırma ile veri seti içerisindeki gemi resimlerini farklı oryantasyon, skala ve kaydırma değerleri kullanılarak veri seti büyütülmüş bu işlemin sınıflandırmaya katkısı ortaya konmuştur.
4. Öznitelik çıkarma öncesinde farklı bantlarda (alçak ve yüksek) filtreler ile işlenmiş imgeler üzerinden eğitilen modellerin farklı skalalarla ayrıştırmada birbirlerine oranla avantaj ve dezavantajları olabileceği düşünülmüş ve bu çıktıların sonsal füzyonu (late fusion) gerçekleştirilmiş ve başarımın %1,7 ile %4 oranında arttırıldığı gözlemlenmiştir.
5. Farklı tip özniteliklerin (HOG, TPLBP ve FPLBP) füzyonunun başarımına etkileri incelenmiştir.

Takip eden bölümler şu şekilde oluşmaktadır. İkinci bölümde bu tez çalışmasına yönelik metodolojiler sunulmuştur. Üçüncü bölümde sırasıyla veri setinin farklı filtreler uygulanarak sınanması, HOG ve LBP öznitelik çıkarımlarının veri seti üzerindeki etkileri ile bunların 1. basamak ve 2. basamak füzyonlarının incelenmesi deneylerinin sonuçları verilmiş ve son bölümde tartışma, sonuçlar ve gelecek çalışmalara yönelik görüşler sunulmuştur.

2. METODOLOJİ

Bu bölümde, gemi sınıflandırma problem çözümüne yönelik metodoloji, kullanılan veri setinin tanıtımı ve izlenen yöntemler uyarınca aşağıda verilen akış diyagramında da gösterildiği gibi alt maddelerde sunulacaktır.



Şekil 2. 1: Otomatik Savaş Gemisi Sınıflandırma Akış Diyagramı



2.1 Veri Seti

Türk Deniz Kuvvetleri envanterinde 8 ana sınıfta 150'nin üzerinde savaş gemisi yer almaktadır (Türk Deniz Kuvvetleri Komutanlığı, 2019). Bu gemiler ve adetleri Tablo 2.1'de verilmiştir.

Tablo 2.1: Türk Deniz Kuvvetleri Envanterinde Bulunan Gemi Tipleri

S.Nu	Gemi Tipi	Adedi	Resmi
1	Gabya Sınıfı Fırkateyn	8	

Tablo 2.1-devam

2	Meko Sınıfı Fırkateyn	8	
3	Ada Sınıfı Korvet	3	
4	Burak Sınıfı Korvet	6	
5	Hücumbot	19	
6	YTKG	16	

Tablo 2.1-devam

7	Denizaltı	12	
8	Çıkarma Gemileri	26	
9	Mayın Gemileri	15	
10	Yardımcı Sınıf Gemiler	50	

Fırkateynler, üzerlerinde barındırdıkları satıhtan satıha ve satıhtan havaya güdümlü mermileri ve büyük çaplı toplar nedeniyle Türk donanmasının ana vurucu gücünü oluşturmaktalar. 2012 yılından itibaren donanmamız envanterine girmeye başlayan ve 2023 yılında toplam adedi 6 olacak olan MİLGEM olarak tabir edilen Ada sınıfı korvetler fırkateynlerle benzer özellik sergilemekte, 100 metreyi anca bulan boyutlarına karşın fırkateynlerle birlikte Türk donanmasının ana vurucu gücünü oluşturmaktadırlar. Korvet sınıfında yer alan bir diğer gemi tipi ise Burak sınıfı korvetler olup, büyük çaplı toplara sahip olmasına karşın üzerlerinde herhangi bir

güdümlü mermi barındırmamaktadırlar. Yüksek yakıt kapasitesi nedeniyle açık denizlerde uzun süreli görevler yapabilmekteler. Hücumbotlar ise daha küçük boyutları ve akaryakıt kapasitelerinin görece düşük olması nedeniyle üzerlerinde barındırdıkları satıhtan satıha güdümlü mermilerine karşın yakın sularda görev yapmaktadırlar. Donanmamızın bir diğer sınıfını oluşturan Yeni Tip Karakol Gemileri (YTKG) toplam 16 adet olup İstanbul'dan İskenderun'a kadar Türkiye'nin çeşitli deniz üslerinde bulunmakta ve boğaz, körfez ve kıyı hattının korunmasında görev almaktadırlar. Yukarıda belirtilen gemi tipleri dışında bulunan gemiler mayın hareketi ve çıkarma hareketi gibi daha özel görevler üstlenmektedirler. Bunların yanı sıra Türk donanmasının envanterinde çeşitli tip ve sınıfta birçok yardımcı sınıf gemi yer almaktadır. Yukarıda belirtilen suüstü gemilerinin yanı sıra büyük bir sürpriz etkisine sahip olan denizaltı gemileri de yine Türk donanmasının asli güçlerindedir.

Bu çalışmada hem sahip oldukları etkin savaş güçleri nedeniyle (güdümlü mermi ve büyük çaplı toplar) hem de birbirlerine çok benzemesi dolayısıyla ayırt ediciliğin testi niteliğinde 4 ana sınıfta (firkateyn, korvet, hücumbot ve karakol) toplam 9 sınıflandırma kategorisine ayrılmış ve 60 Türk savaş gemisi değerlendirmeye alınmıştır. Türk donanmasının temel güçlerinden olmasına karşın denizaltılar, ayırt edici özelliklerinin çok yüksek olması nedeniyle çalışma dışı tutulmuşlardır.

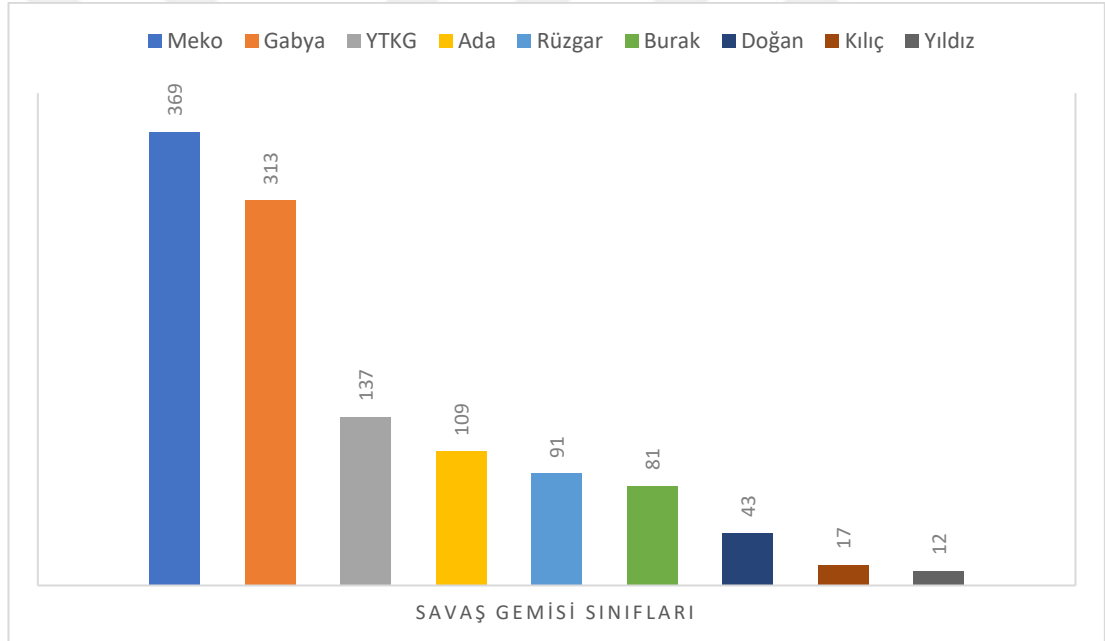
2.1.1 Veri Madenciliği

Veri Madenciliği kapsamında söz edilen sınıflara ait savaş gemilerinin imgeleri açık kaynaklardan derlenerek işlenmiştir. Bununla birlikte, istihbarati nedenlerden dolayı savaş gemilerine ait fotoğrafların açık kaynaklarda bulunması kontrollü ve nispeten düşük sıklıkta olduğundan, madenciliği gerçekleştirilen veri seti kısıtlı boyutlarda olabilmektedir. Bu çalışmada sınıflandırmaya tabi tutulan 60 savaş gemisi için toplam 1483 imge toplanmıştır. Aşağıda örnekleri verilen bazı imgeler, başka savaş gemileri ile birlikte limana bağlı bulunmaları, üzerlerine aborda durumda diğer savaş gemilerinin bulunması, geminin önemli bir bölümünün kadraj dışında kalmış olması, imgeler üzerinde reklam yazılarının yer alması gibi nedenlerden ötürü toplanan imgelerin yaklaşık olarak 1/5'i çalışmaya dahil edilememiş ve toplamda 1172 imge üzerinde çalışma yapılmıştır.



Şekil 2.2: Değerlendirme Dışı Tutulan İmge Örnekleri.


Üzerinde çalışma yapılan imgelerin dağılımı Şekil 2.3'te gösterilmiştir.



Şekil 2.3: Veri Seti Boyutu ve Dağılımı.

2.2 Veri Önışleme

Veri önışleme, sınıflandırma probleminin ilk ve en önemli bölümlerinden birisidir (Oğuzlar, 2003). Bu aşamada resimlerin kırılması, yeniden boyutlandırılması, RGB skaladan Gri Skalaya çevirme vb. işlemler yapılmaktadır. Bu sayede öznelik vektörlerinin doğru olarak elde edilmesi için gerekli düzenlemeler tamamlanmış olur. Veri önışleme akış diyagramı Şekil 3.4'te olduğu gibidir.



Şekil 2.4: Veri Önİşleme Akış Diyagramı.

Veri madenciliğinin tamamlanmasının ardından toplanan imgeler, gemiyi bütünüyle içerecek ve merkeze alacak şekilde diğer gemi ve deniz araçları, bulutlar, arka plan gürültüleri vb. inceleme dışı tutmak amacıyla kırılmıştır. Gelişİ güzel ve belirli bir amacı olmadan açık kaynaklara yüklenen ve birden çok kaynaktan elde edilmiş çok çeşitli imgelerin otomatik olarak kırılmasındaki güçlükler nedeniyle bu aşama manuel olarak yapılmıştır. Daha sonra algoritma içerisinde tüm resimler otomatik olarak RGB skaladan Gri skaya dönüştürülerek 512x512 piksel olarak boyutlandırılmıştır. Şekil 2.5'te orijinal imgeden önİşleme sonrası elde edilen imgeler görölmektedir.



Orijinal Resim



Kırpma ve Yeniden boyutlandırma

Şekil 2.5: Önleme Öncesi ve Sonrası İmge Örneği.

Açık kaynaklardan toplanan imgelerin boyutlarının çeşitlilik göstermesi nedeniyle özniteliklerinin çıkarılması sürecinde hata yapılmasının önüne geçmek amacıyla tüm imgelerin tek bir boyuta indirgenmesi önem arz etmektedir. Bu nedenle, nihai sınıflandırma işleminde, yapılan deneyler sonucunda Şekil 3.4'te de açık bir şekilde görüldüğü üzere en yüksek verimin alındığı ve standart sapmasının en düşük olduğu 512 X 512 boyutu seçilmiştir.

2.2.1 Ön Filtreleme

Filtreleme Giriş: Astronomi ve coğrafi sistem alanlarında yapılan araştırmaların yanı sıra uydu yayınları, MRI, bilgisayarlı tomografi gibi dijital imgeler günlük yaşamda önemli roller oynamaktadır (Motwani, 2004). Çoğu bilgisayarlı görüntü ve grafik işleme uygulamasında gürültüyü azaltmak ve/veya daha kullanışlı imge yapıları elde etmek için filtre kullanılır (He, 2010).


Filtrelemede, imge görüntüsü $f(i,j)$ ile filtre fonksiyonu $h(i,j)$ konvolüsyon işlemine tabi tutulur. Bu işlem matematiksel olarak aşağıdaki gibi ifade edilir.

$$g(i,j) = h(i,j) * f(i,j) \quad (2.1)$$

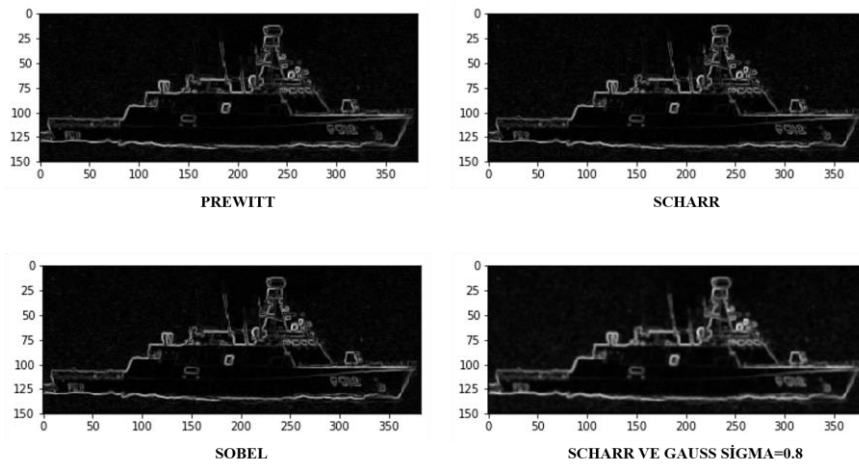
Konvolüsyon; matris formundaki çekirdeğin (kernel), resmi oluşturan piksellerle çarpma işlemine tabi tutulması olarak ifade edilir. Önceden belirlenen çekirdek matrisinin boyutunda işlem yapıldıktan sonra çekirdek kaydırılarak işleme devam edilir ve bu tüm resme uygulanır.



Şekil 2.6: Filtre Uygulanmamış Gemi İmgesi.



Şekil 2.7: Alçak Geçirgen (Low Pass) Filtre Uygulamaları.



Şekil 2.8: Yüksek Geçirgen (High Pass) Filtre Uygulamaları.

Yukardaki şekillerde de açıkça görüldüğü gibi filtreler temelde Alçak Geçirgen (Low Pass) ve Yüksek Geçirgen (High Pass) olmak üzere ikiye ayrılır. Her iki tür filtrelemenin farklı amaç ve kullanım alanları olduğu gibi aynı imge üzerinde birlikte de kullanılabilirler. Alçak geçirgen filtreler olarak Gauss, Median ve Mean, yüksek geçirgen filtreler olarak ise Sobel, Scharr, Prewitt, Laplacian ve Roberts en çok bilinen filtrelerdir.

Yüksek geçirgenli filtreler temelde kenar tespiti amacıyla uygulanır (Lee, 1980). Şekil 3'te gösterildiği gibi yüksek geçirgen uygulanan imge, filtre çekirdeğinin negatif değerler barındırması nedeniyle konvolüsyon işlemi sonucunda kenar/köşe geçişleri gibi keskin değer farklılıkları barındıran pikseller dışında kalan pikselleri başarılı bir şekilde pasifize edebilmektedir.

Alçak geçirgenli filtrelerin çalışma prensibi ise daha farklıdır. Alçak geçirgen filtreler temelde imgenin yumuşatılması (blurring/smoothing) amacıyla uygulanır (Burt, 1983). Mean ve medyan filtrelerinde sırasıyla ortalama ve orta değerler temel alınarak yumuşatma işlemi tamamlanır. Bunun avantajlarının yanı sıra bazı dezavantajları da vardır. Özellikle mean filtrenin uygulanması sonucunda basit bazı gürültüler ortadan kaldırılırken kenar/köşe detaylarında ciddi kayıplar oluşabilir (Motwani, 2004). Medyan filtrede ise tuz ve biber gürültüleri gibi iletim kaynaklı gürültülerin hemen hepsi başarılı bir şekilde kaldırılırken görece daha büyük gürültüler uygulama dışı kalabilmektedir. Gauss filtresi gibi çekirdek uygulaması yapan alçak geçirgen filtreler uygulama sonucunda iletim kaynaklı gürültüleri başarılı bir şekilde ortadan kaldırırken kenar/köşe detaylarında önemsenmeyecek kayıplara neden olmaktadır. Bunun temel nedeni ise çekirdeğin yapısının kullanıcı tarafından belirlenen bir standart sapma değeri ile işleme tabi tutulmasıdır. Böylece çekirdeğin uygulandığı bölge gauss dağılımına tabi yeni değerler alır.

Sözü edilen yüksek geçirgen filtrelere ait çekirdekler Şekil 2.9 ve Şekil 2.10'da olduğu gibidir.

$$G_x = \begin{array}{|c|c|} \hline 1 & 0 \\ \hline 0 & -1 \\ \hline \end{array} \quad G_y = \begin{array}{|c|c|} \hline 0 & 1 \\ \hline -1 & 0 \\ \hline \end{array}$$

Şekil 2.9: Roberts Çekirdeği.

$$S_x = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

Şekil 2.10: Sobel Çekirdeği.

Bu çalışmada yüksek geçiren filtre olarak Scharr ve alçak geçiren filtre olarak Gauss filtresi kullanılmıştır

$$S_x = \begin{bmatrix} 3 & 0 & -3 \\ 10 & 0 & -10 \\ 3 & 0 & -3 \end{bmatrix} \quad S_y = \begin{bmatrix} 3 & 10 & 3 \\ 0 & 0 & 0 \\ -3 & 10 & -3 \end{bmatrix}$$

Şekil 2.11: Scharr Çekirdeği.

Yüksek geçirenli Scharr Filtresi kullanılmasının nedeni gemilerinin sahip oldukları geometrilerinin daha yumuşak olarak ortaya konulmasıdır (Scharr, 2007). Bunun sonucunda ise öznelilik vektörleri daha verimli olarak elde edilmiştir.

Sobel ve Scharr filtrelerine yönelik karşılaştırma aşağıda gösterilmiştir.



0,1187	0,0444	0,1197	0,1265	0,1221	0,1886
0,1142	0,1741	0,2134	0,3216	0,3386	0,2557
1,0364	1,2151	1,4525	1,437	1,3166	1,359
1,4396	1,4476	1,4009	1,2878	1,2785	1,2905
0,8393	0,7245	0,5147	0,4692	0,5574	0,4707
0,3694	0,3533	0,2753	0,2435	0,258	0,2585

Sobel Filtresi



0,5637	0,2332	0,5491	0,4812	0,5071	0,7996
0,5193	0,6094	0,8751	1,2348	1,5321	0,8136
4,2255	4,6647	6,1071	4,4168	5,4252	5,0972
5,7607	5,7423	4,1808	5,1734	3,2909	5,3849
3,2941	3,0464	1,9934	1,9805	2,0336	2,1985
1,4938	1,488	1,0477	0,9741	1,0371	1,0309

Scharr Filtresi

Şekil 2.12: Sobel ve Scharr Filtrelerinin Karşılaştırması.

Scharr filtresinin uygulaması aşağıda ayrıntılarıyla anlatılmıştır.

$$G_x = \begin{bmatrix} 174 & 176 & 174 & 164 & 162 & 161 & 162 \\ 171 & 168 & 170 & 172 & 169 & 179 & 169 \\ 171 & 165 & 169 & 177 & 167 & 170 & 170 \\ 167 & 159 & 164 & 157 & 153 & 146 & 167 \\ 108 & 97 & 104 & 66 & 86 & 77 & 105 \\ 69 & 71 & 71 & 68 & 70 & 73 & 75 \\ 49 & 48 & 47 & 48 & 49 & 52 & 54 \end{bmatrix} * \begin{bmatrix} 3 & 10 & 3 \\ 0 & 0 & 0 \\ -3 & -10 & -3 \end{bmatrix} = \begin{bmatrix} 134 & 44 & -130 & -116 & -129 & -137 \\ 120 & 132 & 216 & 304 & 384 & 191 \\ 1064 & 1187 & 1548 & 1122 & 1368 & 1292 \\ 1453 & 1461 & 1044 & 1316 & 802 & 1337 \\ 838 & 771 & 462 & 496 & 504 & 558 \\ 378 & 374 & 263 & 240 & 253 & 259 \end{bmatrix}$$

$$G_y = \begin{bmatrix} 174 & 176 & 174 & 164 & 162 & 161 & 162 \\ 171 & 168 & 170 & 172 & 169 & 179 & 169 \\ 171 & 165 & 169 & 177 & 167 & 170 & 170 \\ 167 & 159 & 164 & 157 & 153 & 146 & 167 \\ 108 & 97 & 104 & 66 & 86 & 77 & 105 \\ 69 & 71 & 71 & 68 & 70 & 73 & 75 \\ 49 & 48 & 47 & 48 & 49 & 52 & 54 \end{bmatrix} * \begin{bmatrix} 3 & 0 & -3 \\ 10 & 0 & -10 \\ 3 & 0 & -3 \end{bmatrix} = \begin{bmatrix} 52 & -40 & 52 & -40 & -9 & 151 \\ 56 & 82 & 56 & 82 & -72 & 81 \\ 170 & 77 & 170 & 98 & 206 & 142 \\ 216 & 98 & 216 & -92 & -247 & 313 \\ 58 & -95 & -212 & -95 & -122 & 54 \\ -47 & -64 & -47 & -64 & -77 & -45 \end{bmatrix}$$

$$G_x = \begin{bmatrix} 134 & 44 & -130 & -116 & -129 & -137 \\ 120 & 132 & 216 & 304 & 384 & 191 \\ 1064 & 1187 & 1548 & 1122 & 1368 & 1292 \\ 1453 & 1461 & 1044 & 1316 & 802 & 1337 \\ 838 & 771 & 462 & 496 & 504 & 558 \\ 378 & 374 & 263 & 240 & 253 & 259 \end{bmatrix}$$

$$G_y = \begin{bmatrix} 52 & -40 & 52 & -40 & -9 & 151 \\ 56 & 82 & 56 & 82 & -72 & 81 \\ 170 & 77 & 170 & 98 & 206 & 142 \\ 216 & 98 & 216 & -92 & -247 & 313 \\ 58 & -95 & -212 & -95 & -122 & 54 \\ -47 & -64 & -47 & -64 & -77 & -45 \end{bmatrix}$$

$$G = \sqrt{G_x^2 + G_y^2} = \begin{bmatrix} 0,56367 & 0,233193 & 0,549076 & 0,481188 & 0,507112 & 0,799558 \\ 0,519308 & 0,609397 & 0,875064 & 1,234765 & 1,532124 & 0,813591 \\ 4,225472 & 4,664686 & 6,107085 & 4,416752 & 5,425189 & 5,097176 \\ 5,760656 & 5,742287 & 4,180826 & 5,17338 & 3,290878 & 5,384898 \\ 3,294136 & 3,046395 & 1,993407 & 1,980454 & 2,033552 & 2,198458 \\ 1,493768 & 1,487986 & 1,047712 & 0,974066 & 1,03709 & 1,030903 \end{bmatrix}$$

Not = Normalizasyon amacıyla $\frac{1}{255}$ ile çarpılmıştır.

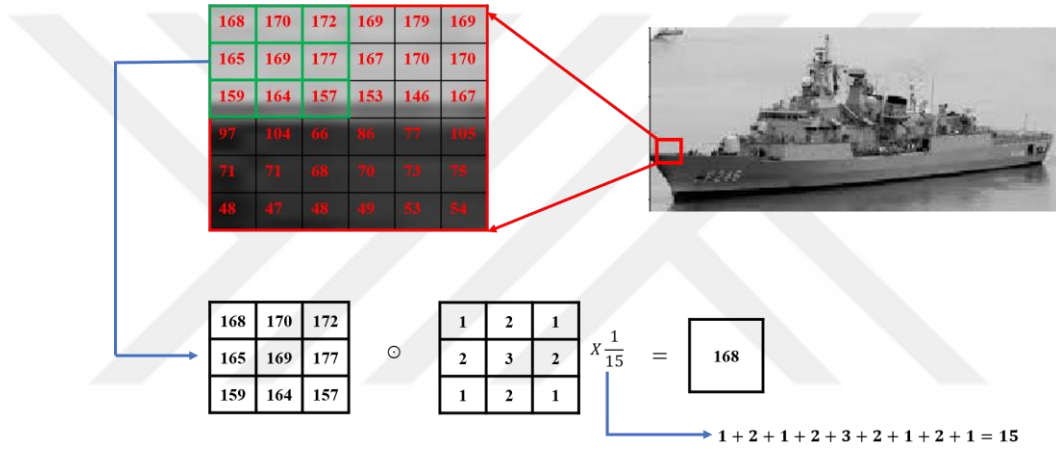
Alçak geçiren olarak kullanılan Gauss Filtresi formülü ve grafiği aşağıdaki gibidir.

$$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.2)$$

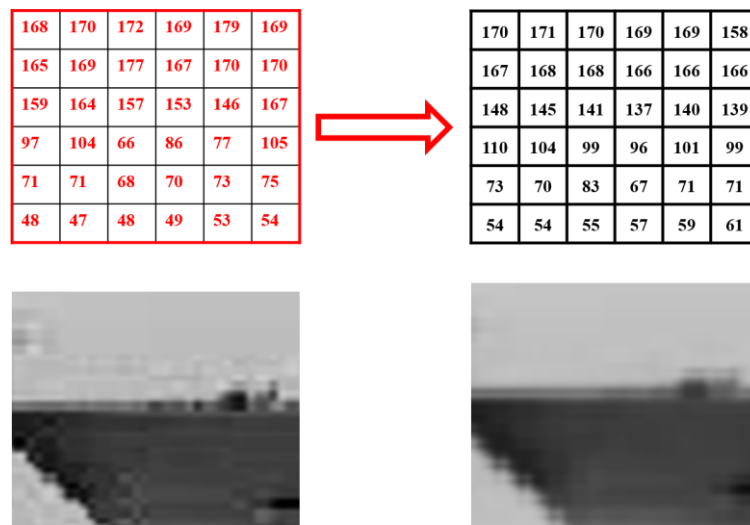
Burada sigma standart sapmayı belirler ve filtre uygulamasında kullanıcı tarafından girilir. Birçok programlama dilinde default değeri olarak 1.0 verilmiştir. Daha yüksek bir değer girildiği takdirde yumuşatma etkisi artacak ve fakat önemli veri kayıpları

yaşanacaktır (Şekil 2.7: Alçak Geçirgen (Low Pass) Filtre Uygulamaları). Çalışmada sigma değeri olarak en yüksek verim 0.8 olarak belirlenmiştir. Gauss filtresinin en önemli özelliği komşu piksel değerlerinin merkez piksel üzerindeki var olan etkisidir (Deng, 1993). Bu nedenle yumuşatma sağlanırken veri kayıpları (sigma yüksek değerler belirlenmedikçe) önemsiz seviyelerde kalacaktır.

Aşağıda TCG SALİHREİS(F-246) fırkateynine ait bir imgeye Gauss filtresi uygulanmıştır. Geminin başüstünden alınan ve kenar geçişini de içeren imgeye Gauss filtresinin uygulanması sonucunda oluşan yeni değerler incelendiğinde yumuşamanın oluşumu ve aynı anda kenar ayrıntılarının korunumu açıkça görünmektedir.



Şekil 2.13: İmge üzerine uygulanan Gauss Filtresinin Örnekleme.



Şekil 2.14: Gauss Filtresi Uygulanması Sonucu Elde Edilen Değerler.

Yukarıda sözü edilen Gauss filtresinin çekirdeği aşağıdaki hesaplama yöntemi ile elde edilmiştir. Farklı sigma değerlerinin seçilmesi sonucunda çekirdek değerleri farklı olacaktır. x ve y 3x3 matris çekirdeğine uyumlu olarak alınmıştır, matris çekirdeği 5x5 veya daha büyük alınırsa bu değerlerde -2 -1 0 -1 -2 şeklinde değişiklik gösterecektir. Gauss çekirdeğinin 5x5 seçilmesi yumuşatmanın daha fazla olması anlamına gelecektir.

Tablo 2.2: Gauss Filtresi Çekirdeği Hesaplama Tablosu.

x	y	Sigma	$\frac{1}{\sqrt{2\pi\sigma^2}}$	$e^{-\frac{x^2+y^2}{2\sigma^2}}$	$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2+y^2}{2\sigma^2}}$	ÖLÇEK: 1/0,130660695 = 7,653410997
-1	-1	0,8	0,623347313	0,209611387	0,130660695	1
0	-1	0,8	0,623347313	0,457833362	0,285389196	2
1	-1	0,8	0,623347313	0,209611387	0,130660695	1
-1	0	0,8	0,623347313	0,457833362	0,285389196	2
0	0	0,8	0,623347313	0,623347313	0,388561873	3
1	0	0,8	0,623347313	0,457833362	0,285389196	2
-1	1	0,8	0,623347313	0,209611387	0,130660695	1
0	1	0,8	0,623347313	0,457833362	0,285389196	2
1	1	0,8	0,623347313	0,209611387	0,130660695	1

Gauss Çekirdek Matrisi =

1	2	1
2	3	2
1	2	1

x $\frac{1}{15}$

Şekil 2.15: Gauss Çekirdeği.

2.3 Öznitelik Çıkarımı

İmgeler, renk, nesne, kenar , piksel tanımlamaları, boyutlar ve diğer benzeri özellikleri ile büyük miktarda bilgiler içerir. Bu nedenle imge işleme bu verilerin tamamını korumak amacıyla hassas bir ilgi ister (Mandloi, 2014). Sınıflandırma işleminin en önemli adımlarından birisi de öznitelik vektörlerinin doğru olarak çıkarılmasıdır. Sınıflandırma algoritması üzerinde doğrudan etkiye sahip bu işlem için günümüzde kullanılan bir çok yöntem olmasına karşın bu çalışma kapsamında Gradyan Yönelimlerinin Histogramı (HOG-Histogram of Oriented Gradient) ile Yerel İkili Örüntü (LBP-Local Binary Pattern) tercih edilmiştir. Bunun temel nedeni ise HOG algoritmasının geometrideki başarısı ve LBP'nin ise genel kabul görmüş bir yöntem olmasıdır.


2.3.1 Gradyan Yönelimlerinin Histogramı (HOG-Histogram of Oriented Gradients)

İlk olarak Dalal ve arkadaşları tarafından geliştirilen Histogramların Yönelim Eğrileri (Dalal, 2005) yaklaşımı temel olarak yayaaların tespitini amaçlamaktadır. Bu yöntemde imge, kullanıcı tarafından belirlenen lokal parçalara ayrılarak histogramlar halinde betimlenir. Bu histogramlar, yine kullanıcı tarafından belirlenen sayıda piksellerin yönelimlerinden oluşmaktadır. HOG betimleyicisinin işlem basamakları şu şekildedir:

- İmgenin hücelere ayrılarak gradyanlarının oluşturulması,
- Çıkarılan gradyanların yönelimlerinin çıkarılması,
- Oluşan histogramların blok bazında normalize edilmesi

HOG algoritmasında bir imge, kullanıcının amacına yönelik olarak istenen sayıda hücelere ayrılır. Söz konusu hücelerden oluşan bloklar tanımlanır ve normalizasyonun boyutu elde edilmiş olur. Hücre boyutu ve blok boyutu belirlendikten sonra her hücrenin histogramı çıkartılır ve bu histogramlara istinaden yönelim eğrileri yani öznitelik vektörleri elde edilir. Ada sınıfı korvete ait bir imgenin 32×32 'lik hücre boyutlu ve 4×4 blok (normalizasyon) boyutlu hesaplama modeli, öznitelik vektörlerinin elde edilmesi Şekil 2.16'da gösterilmiştir.


Aşağıda tüm imgeye ait HOG öznitelik vektörleri gösterilmiştir.



Şekil 2.16: Önışleme Yapılmış Gemi İmgesinde HOG Özniteliklerinin Görseli. (Blok Boyutu 4x4, Hücre Boyutu 32x32 Alınmıştır)

Böylece $I_x \times I_y$ boyutlarındaki bir imgeden, $C_x \times C_y$ hücre ve $B_x \times B_y$ blok boyutlarında ve O oryantasyon ayrıntısında çıkarılan HOG özniteliklerinin boyutu Eşitlik 2.3’de verildiği gibi hesaplanabilmektedir.


$$HOG = \left(\frac{I_x}{C_x} - (B_x - 1) \right) \left(\frac{I_y}{C_y} - (B_y - 1) \right) B_x B_y O \quad (2.3)$$




Şekil 2.17: HOG Özniteliklerinin Boyutunun Açıklanması.

2.3.2 Yerel İkili Örüntü (LBP-Local Binary Pattern)


2002 yılıyla birlikte Ojala ve arkadaşlarının çalışmaları sonrasında LBP büyük popülarite kazanmıştır (Ojala, 2002). Bu zamana kadar başarılı sınıflandırma algoritmaları üretilmiş olsa da söz konusu algoritmaların karşılaştıkları en büyük sorun imgelerin farklı açılarda ve kontrastlarda farklı değerler üretmesine karşın aynı imge olarak değerlendirilememesiydi. Ojala ve arkadaşları önerdikleri yaklaşım ile bu sorunu ortadan kaldırmayı başarmışlar ve böylece aynı imgeye ait farklı açı ve parlaklık değerlerinde olan imgeler sınıflandırma üzerinde olumsuz etki yaratmamışlardır. Uygulamacılar bu sorunu P ve R şeklinde tanımladıkları iki değişken ile çözüme ulaştırmışlardır. Söz konusu yaklaşıma göre $LBP_{P,R}^{riu2}$ yapısal uzayı yani açisal değişimi incelerken VAR_{PR} gri scaladaki kontrast farkını incelemektedir. Yaklaşıma yönelik farklı P ve R değerlerinin imge üzerindeki hesaplamaları aşağıda olduğu gibidir.



Şekil 2.18: LBP Hesaplama Modelleri.




Hesaplamaadaki kolaylık ve işlem hızının yanı sıra LBP modellemede otomatikman boyut küçültmede yapılmaktadır. Bu da bir taraftan işlem hızını artırırken bir taraftan doğruluk üzerinde olumlu etkilere neden olmaktadır.



Şekil 2.19: LBP Uniform Geçiş Değerleri.

Uniform ifadesi 1-0 ve/veya 0-1 geçişlerinin sayısının iki ve daha az olduğu durumları tanımlar. LBP, uniform dışında kalan yani üç ve daha fazla geçişli hesaplamaları değerlendirme dışı tutar. Bir imgenin yaklaşık %90'nın uniform olduğu (Ojala, 2002) söz önüne alındığında ciddi bir veri kaybının olmadığı görülecektir. Buna karşın hızda belirgin bir artış yaşanmaktadır. Bunun yanı bu işlemin asıl başarısı boyut küçültmede yatmaktadır. Yalnızca uniform olan 59 değer hesaplamaya alındığında öznelik vektörlerinin sayısı 256'dan 59'a indirgenmekte bu durum ise başarıya olumlu katkılar sağlamaktadır.

Meko sınıfı bir fırkateyne ait iki örnek LBP hesaplaması aşağıda görüldüğü gibidir.



Şekil 2.20: P=8, R=1 için Örnek LBP Hesaplama Modeli.

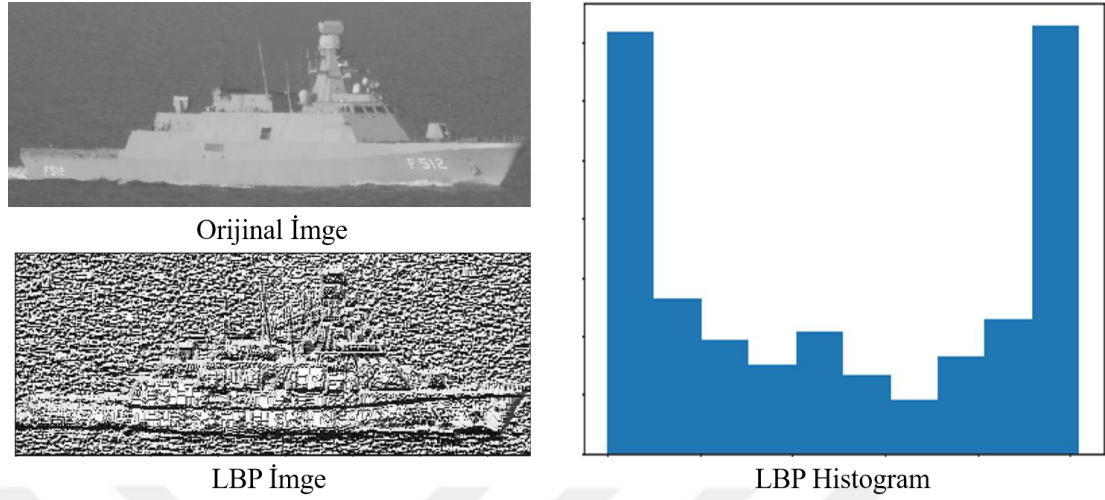
Yukarıda açıklanan komşuluk bağlantısı nedeniyle aydınlatma seviyesindeki değişim $g_p - g_c$ piksel farkında bir değişime neden olmaz. Ortak değerlerin alınması nedeniyle değişmezlik sağlanmış olur. LBP'nin en büyük iki başarısından birisi bu yöntem ile gerçekleştirilmiş olmaktadır (Ahonen, 2004).

Buradan yola çıkarak LBP için;

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_0) 2^p \quad (2.4)$$

Denklemini elde edilmiş olur.

Aşağıdaki resimde ADA sınıfı bir korvetin LBP ile elde edilmiş imgesi ile histogramı görülmektedir.



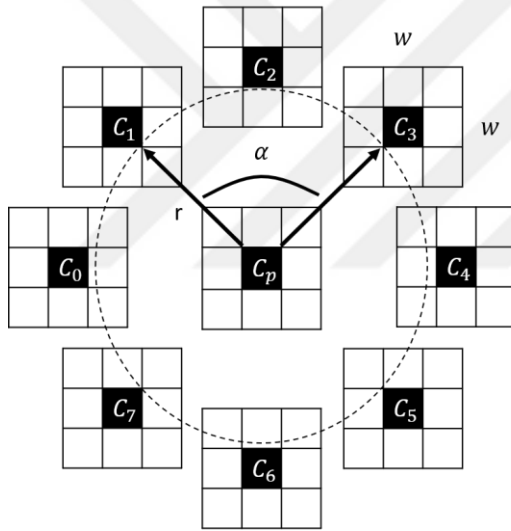
Şekil 2.21: TCG BÜYÜKADA'ya Ait LBP İşleme Örneği.

Yüz tanıma sisteminde başarılı bir şekilde kullanılan LBP algoritması Savaş Gemisi Sınıflandırmada başarılı sonuçlar vermemiştir. Bunun nedeninin kişilerin yüz hatlarında ciddi ayrımlara neden olabilecek farklılıklar küçük piksel farklarında ortaya çıkarken (yüz tanımda dahi fazla yerel bölümleri incelemesi nedeniyle daha başarılı sonuçlar elde edebilmek amacıyla geliştirilmiş LBP uygulamalarına ihtiyaç duyulmaktadır (Ahonen, 2004), (Liao, 2007)) gemi imgelerinin sınıflandırılmasında birbirine yakın pikseller büyük anlamlar taşımamaktadır. Bu nedenle sınıflandırma çalışmalarında tüm test imgeleri en yüksek sayıda imge içeren sınıf olan MEKO sınıfına yönelerek tüm testi bu sınıf üzerinden yapmış başarı yalnızca %30'larda kalmıştır.

Bununla birlikte Wolf ve arkadaşları tarafından geliştirilen (Wolf, 2008) ve yine LBP temelli olan TPLBP ve FPLBP algoritmaları ile yapılan sınıflandırmada %75'in üzerinde başarı elde edilmiştir. Bunun temel nedeninin ise LBP'den farklı olarak TPLBP ve FPLBP algoritmalarının yalnızca komşu pikselleri değil aynı zamanda komşu blokları da göz önüne almasından kaynaklandığı değerlendirilmektedir. Bu sayede gemi imgeleri üzerindeki nispeten daha geniş bölgeye yayılan ayırt edici öznitelikler daha belirgin hale gelmektedir.

İsminden de anlaşılacağı gibi Three-Patch LBP (TPLBP) kodu, her bir piksel için tek bir değer üretmek amacıyla üç bloğun değerlerinin karşılaştırılmasıyla elde edilmektedir. İlk olarak her bir pikselin değerini hesaplamak için merkezinde söz konusu piksel olacak şekilde $w \times w$ boyutunda bir blok ele alınır. Blok etrafında uniform olarak dağılmış r çaplı S adet blok değerlendirmeye tabi tutulur. Parametre olarak kullanılan α , merkezden kaç birim ayrı iki bloğun seçileceğine karar verir. Sonuçta piksel başına S bit değer elde edilmektedir. TPLBP değerleri aşağıdaki formül ile hesaplanmaktadır.

$$TPLBP_{r,S,w,\alpha}(p) = \sum_i^S f(d(C_i, C_p) - d(C_{i+\alpha \bmod S}, C_p)) 2^i \quad (2.5)$$



$$\begin{aligned}
 TPLBP_{r,8,3,2}(p) = & \\
 & f(d(C_0, C_p) - d(C_2, C_p)) 2^0 + \\
 & f(d(C_1, C_p) - d(C_3, C_p)) 2^1 + \\
 & f(d(C_2, C_p) - d(C_4, C_p)) 2^2 + \\
 & f(d(C_3, C_p) - d(C_5, C_p)) 2^3 + \\
 & f(d(C_4, C_p) - d(C_6, C_p)) 2^4 + \\
 & f(d(C_5, C_p) - d(C_7, C_p)) 2^5 + \\
 & f(d(C_6, C_p) - d(C_0, C_p)) 2^6 + \\
 & f(d(C_7, C_p) - d(C_1, C_p)) 2^7
 \end{aligned}$$

Şekil 2.22: TPLBP Hesaplama Modeli ($S=8, w=3, \alpha=2$).

C_p merkez blok olmak üzere C_i ve $C_{i+\alpha \bmod S}$ merkez blok etrafındaki iki ayrı bloktur. $d(.,.)$ fonksiyonu ise iki blok arasındaki mesafe fonksiyonu ve f aşağıdaki şekilde tarif edilmektedir;

$$f = \begin{cases} 1 & \text{eğer } x \geq \tau \\ 0 & \text{eğer } x < \tau \end{cases} \quad (2.6)$$

τ , uniform alanlarda stabiliteyi sağlamak adına sıfırdan çok az büyük ($\tau = 0.01$) bir

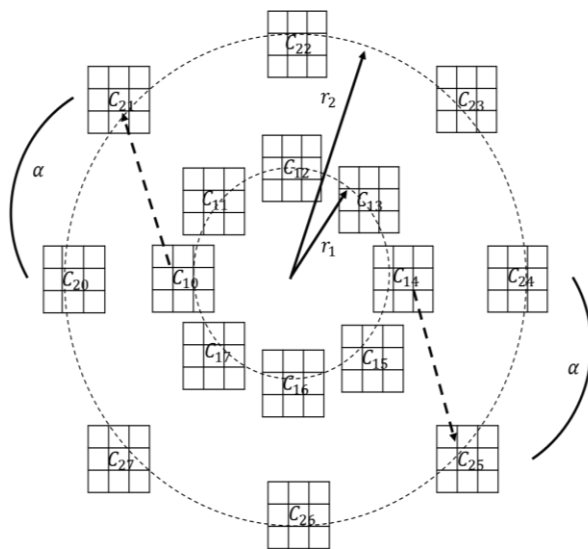
değer olarak seçilmektedir. Bundan sonraki hesaplamalar CSLBP' (Heikkilä, 2009) de olduğu gibi yapılmaktadır.

Yani;

LBP	CSLBP
$ \begin{aligned} &S(n_0 - n_c)2^0 + \\ &S(n_1 - n_c)2^1 + \\ &S(n_2 - n_c)2^2 + \\ &S(n_3 - n_c)2^3 + \\ &S(n_4 - n_c)2^4 + \\ &S(n_5 - n_c)2^5 + \\ &S(n_6 - n_c)2^6 + \\ &S(n_7 - n_c)2^7 \end{aligned} $	$ \begin{aligned} &S(n_0 - n_c)2^0 + \\ &S(n_1 - n_c)2^1 + \\ &S(n_2 - n_c)2^2 + \\ &S(n_3 - n_c)2^3 \end{aligned} $

Şekil 2.23: LBP ve CSLBP Hesaplama Modeli.

TPLBP ve FPLBP uygulanırken CSLBP(Center-Symmetric Local Binary Pattern)'den temel farklılıklardan birisi de interpolasyon yerine en yakın komşunun değerinin alınmasıdır. Bu sayede değerlendirme üzerinde etki yaratılmazken işlemler hızla tamamlanmaktadır. Hesaplama tamamlandıktan sonra imge overlap olmaksızın gridlere ayrılarak her bir bölgede yer alan değerlerin frekanslarına istinaden histogramları elde edilir.



The diagram illustrates the FPLBP calculation model. It shows a central pixel (C11) surrounded by 24 neighbors (C10, C12, C13, C14, C15, C16, C17, C18, C19, C20, C21, C22, C23, C24, C25, C26, C27, C28, C29, C30, C31, C32, C33). The neighbors are arranged in a grid. The distance from the center to the neighbors is labeled as r1 and r2. The angle between the center and the neighbors is labeled as alpha. The formula for FPLBP is given as:

$$\begin{aligned}
 FPLBP_{r_1, r_2, 8, 3, 1}(p) = & \\
 &f(d(C_{10}, C_{21}) - d(C_{14}, C_{25}))2^0 + \\
 &f(d(C_{11}, C_{22}) - d(C_{15}, C_{26}))2^1 + \\
 &f(d(C_{12}, C_{23}) - d(C_{16}, C_{27}))2^2 + \\
 &f(d(C_{13}, C_{24}) - d(C_{17}, C_{20}))2^3
 \end{aligned}$$

Şekil 2.24: FPLBP Hesaplama Modeli.

2.4 Normalizasyon

Önişleme basamaklarından birisi olan normalizasyon işlemi yapay öğrenmede genelde öznitelik vektörlerinin elde edilmesinden sonra uygulanır. Bu çalışmada da standart scale normalizasyonu, öznitelik vektörlerinin elde edilmesinin ardından uygulanmıştır. Öznitelik vektörleri elde edildikten sonra ortalama değeri hesaplandığı takdirde bu rakam sıfırdan oldukça farklı çıkacaktır. Bu da verilerin geniş bir ölçekte dağılması ve dolayısıyla da standart sapmanın çok yüksek olması anlamına gelir (Xie, 2015). Özellikle boyut küçültme uygulanırken (Bu çalışmada boyut küçültme algoritması olarak Temel Bileşen Analizi -PCA kullanılmıştır.) ölçek büyük önem kazanmaktadır. Bu durum ise elde edilmesi gereken başarının büyük oranda düşmesine neden olur. Bunu engellemenin yolu kuşkusuz ortalamanın sıfıra çekilmesi ve standart sapmanın bire indirgenmesidir. İşte normalizasyon tam olarak burada devreye girmektedir. Elde edilen veriler standart scale ile normalize edildikten sonra ortalaması sıfıra veya sıfıra yakın bir değere ve standart sapması bire eşitlenir.

$$\begin{aligned}x &\in \mathcal{R}^D \text{ olsun} \\x &= \{x_1, x_2, \dots, x, \dots, x\} \\X &= \{x^{(1)}, x^{(2)}, \dots, x^{(t)}, \dots, x^{(N)}\} \in \mathcal{R}^{D \times N}\end{aligned} \quad (2.7)$$

Standardizasyon;

$$z_i = \frac{x_i - \mu_i}{\sigma_i} \quad (2.8)$$

Ortalama;

$$\mu_i = \frac{1}{N} \sum_{t=1}^N x_i^{(t)} \quad (2.9)$$

ve Standart Sapma;

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{t=1}^N (x_i^{(t)} - \mu_i)^2} \quad (2.10)$$

formülleri ile hesaplanır.



Şekil 2.25: ADA Sınıfı Korvete Ait Örnek İmge.

Veri setimizden alınan ve yukarıda gösterilen ADA sınıfı bir korvete ait imgenin normalize edilmmeden önceki örnek değerleri şu şekildeyken

Normalize Edilmemiş Ortalama Değer : array([112.39333333, 112.54, 112.81333333, 112.50666667, 112.63333333, 112.96666667, 113.18, 113.41333333, ...])

Normalizasyon uygulandıktan sonraki örnek değer aşağıda olduğu şekilde elde edilmiştir.

Normalize Edilmiş Ortalama Değer : array([8.95579907e-17, -3.02720811e-16, 1.77635684e-17, 2.56831593e-16, -2.70894418e-16, -8.88178420e-17, -3.49720253e-16, 3.27145718e-16,...])

Görüldüğü gibi normalize edilen değerler sifıra oldukça yakındır.

Standart sapmadaki durum ise aşağıda gösterildiği gibidir;

Normalize Edilmemiş Standart Sapma : array([20.59187434, 19.90330961, 20.09822104, 19.1929663, 20.10950577, 20.50314339, 20.14450132, 20.75899377, 21.18897407, 22.10930021,...])

Normalize Edilmiş Standart Sapma : array([1., 1., 1., 1., 1., 1., 1., 1., 1., 1., ...])

Yukarıda da açıkça görüldüğü gibi normalizasyondan sonra standart sapma değeri bire eşitlenmiştir. Normalizasyon yapılması bu çalışmada başarı oranını yaklaşık %5 oranında arttırmıştır.

2.5 Dekorelasyon ve Boyut Azaltma

Sınıflandırma probleminin idealinde boyut azaltma ya da artırma işlemlerine gerek kalmaksızın, sınıflandırıcının tüm öznelik vektörlerini ilgili olup olmadığına bakmaksızın kullanması istenir. Ancak bu, birçok sorunu da beraberinde getirmektedir. Bu sorunlar, maliyetin artması, işlem yoğunluğuna bağlı olarak zamanın artması ve çok daha önemlisi gereksiz öznelik vektörleri üzerinde (Fodor, 2002) işlem yapılması sonucunda istenilen doğruluktan uzak kalınmasına yol açmaktadır. Söz konusu olumsuz durumlardan kaçınmanın temel yolu ise sınıflandırıcı açısından büyük önem arz eden öznelik vektörlerinin kullanılması, veri üzerinde etkili olmayanların kullanılmamasıdır. Bunun yöntemi ise boyut azaltmadır. Yukarıda açıklanan yararlarının yanı sıra boyut azaltma özellikle nispeten daha küçük veri setine sahip çalışmalarda büyük yararlar sağlamaktadır (Alpaydın, 2012).

Öznelik vektörleri üzerinde boyut küçültme işlemi, sınıflandırma üzerinde doğrudan etki yaratacak temel verileri korurken neredeyse hiçbir katkı sağlamayacak olan önemsiz öznelik vektörlerini uygulama dışında tutmaktadır. Boyut azaltma işlemini en iyi yapan algoritmalarından birisi de Temel Bileşen Analizi (PCA-Principle Component Analysis)'dir (Maaten, 2009), (Fodor, 2002).

Bir projeksiyon yöntemi olan PCA'de temel amaç en az veri kaybı ile öznelik vektörlerini d boyuttan k boyuta azaltmaktır ($k < d$).

Bu sayede x, y, z, \dots koordinat sisteminden yansıtma yapılarak PC_1, PC_2, PC_3, \dots koordinat sistemine geçilmektedir. Bu algoritma, yönleri birbirlerine dik ve varyansları en çok olan bileşenler üzerine temellendirilmiştir (Sorzano, 2014).

PCA çıktı verilerini kullanmayan gözetimsiz bir yöntemdir. PCA'de temel hedef varyansı maksimize etmektir. Birinci Temel Bileşen (PC_1), verilerin varyansı en büyük olan (örnekler bir yüzeye yansıtıldıktan sonra orijine olan uzaklıklarının karelerinin toplamı alınarak hesaplanır) yüzeye yansıtılmasıyla elde edilir.

İlk olarak ortalama değerler alınarak veri değerlerinden çıkarılır ve bu sayede veri

ortalamasının sıfır olması sağlanır ki bu PCA'in tam olarak düzgün çalışmasını sağlar. İlk olarak verinin kovaryans matrisi oluşturulur.

$$C = E((x - \mu)(x - \mu)^T) \quad (2.11)$$


Kovaryans matrisin diogonal kısmı her bir boyutun varyansını verir. Veri seti üzerinden kestirilecek her boyutun varyansı Eşitlik-2.10'da gösterildiği gibi hesaplanır.

$$C_{ii} = \sigma_{x_i}^2 = E((x_i - \mu_i)^2) \quad (2.12)$$

Kovaryans matrisi elde edildikten sonra sıra özdeğerlerin ve özvektörlerin hesaplanmasına gelir. Özvektörler kovaryans matrisinin sıfır uzayında (nullspace) yer alan vektörlerdir ve aşağıda yer alan eşitliğin çözüm kümesidir.

$$|C - \lambda I| = 0 \quad (2.13)$$

Bu denklemi gerçekleyen özdeğerler (λ) yerlerine konarak kendilerine karşılık gelen özvektörler elde edilir. En yüksek özdeğere karşılık gelen özvektör veri setinin en önemli Temel Bileşeni (*Principle Component-PC*)'dir. Çünkü özdeğer arttıkça onun açıkladığı varyans da artar (Büyüköztürk, 2002).

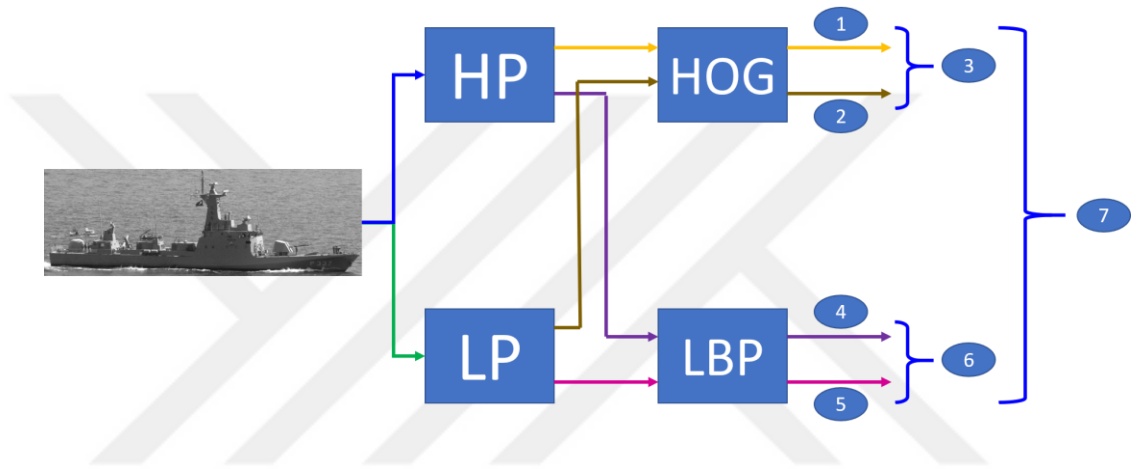


Şekil 2.26: x, y Koordinat Düzleminde PC Koordinat Düzlemine Geçiş.

2.6 Füzyon


Füzyon literatürde var olan bir işlem olmakla birlikte genelde iki farklı kaynaktan elde edilen verilerin füzyon ile birleştirilmesi olarak uygulanmaktadır (Giompapa, 2007). Bu çalışmada ise füzyon işlemi sınıflandırma sonrasında elde edilen değerler üzerinden yapılarak gerçekleştirilmiştir.

Sınıflandırma algoritması şekil dışı bırakılan 2 basamaklı füzyon, aşağıda gösterildiği gibi uygulanmıştır.



Şekil 2.27: İki Basamaklı Olarak Uygulanan Füzyon İşlemi.

Füzyon işlemi yukarıdaki şekilden de anlaşılacağı üzere basamak basamak uygulanmıştır. İlk olarak HOG algoritmasında Yüksek ve Alçak geçiren filtre uygulanan öznitelik vektörleri sınıflandırma sonrasında Füzyon işlemine tabi tutulmuştur. Bu, 1. basamak füzyon olarak adlandırılmıştır. Sonrasında filtreler LBP algoritmasında uygulanmış ve 1. basamak füzyon işlemi yinelenmiştir. Son olarak ilk basamak füzyondan sonra elde edilen veriler SVM algoritması sınıflandırılmış ve ardından söz konusu veriler yeniden füzyona tabi tutulmuştur. Bu da 2. Basamak füzyon olarak adlandırılmıştır.



Şekil 2.28: TPLBP-FPLBP İki Basamaklı Füzyon İşlem Basamakları.

Bu çalışmanın literatüre önemli katkılarından birisi olan füzyonun testi amaçlı LBP temelli sınıflandırıcı olan TPLBP ve FPLBP sınıflandırıcılar arasında da sınanmıştır. Öncelikle alçak geçiren filtre uygulanan TPLBP sınıflandırması yapılmış, ardından yine alçak geçiren filtre uygulanan FPLBP sınıflandırması yapılarak 1. Basamak füzyon uygulanmıştır. Daha bu işlemler yüksek geçiren filtre için de yinelenmiştir. Elde edilen 1. basamak füzyon değerleri 2. basamak füzyona tabi tutulmuştur.


Her iki deney de göstermiştir ki 2 basamaklı olarak uygulanan füzyon, doğruluk üzerinde önemli etkilere neden olmuştur. Her ne kadar zaman zaman 2. basamak füzyon diğer sonuçların altında kalmış olsa da her zaman füzyon uygulanmamış değerlerden daha yüksek verim elde edilmiş ancak 1. basamak füzyonun altında kaldığı anlar deneyimlenmiştir. Genel ortalama da ise 2. basamak füzyon başarı sağlamıştır.

Yukarda açıklanan nedenler dolayı elde edilen son başarı değeri olarak 2. basamak füzyon değerleri temel alınmıştır.

2.7 Sınıflandırma

Bu çalışmada sınıflandırıcı algoritma olarak Destek Vektör Makinesi (SVM-Support Vector Machine) kullanılmıştır. Vapnik tarafından ilk olarak 1995 yılında geliştirilen SVM (Vapnik, 1995) giderek yoğun bir ilgi görmüş ve tüm alanlarda en çok kullanılan sınıflandırıcılardan olmayı başarmıştır (Chang, 2011). Gözetimli bir sınıflandırıcı olan SVM lineer ve ikili sınıflandırma temeline dayanır.

Şekil 2.29: Destek Vektör Makinesi, Marjin ve Destek Vektörleri'da yer alan kahverengi ve açık mavi noktaları birbirinden ayıran lineer bir karar sınırı çizmek aslında çok da zor değil. Fakat zor olan, bu sınır çizgisinin o noktalar arasında yer alan sonsuz tane çizgiden hangisi olduğuna karar vermektir. İşte SVM tam olarak bu noktada devreye girmektedir. SVM, yalnızca sınır çizgisinin yerini belirlemekle kalmamakta aynı zamanda optimum karar sınırını belirlemektedir. Bunu yaparken de karar sınırına en yakın verilerden (örneğimizde noktalardan) yararlanır. Bu noktaların karar sınırına en yakın olduğu yerden birer hat daha çizerek marjini ve marjinin genişliğini belirler. Marjini belirlerken kullanılan bu verilere (noktalara) Destek Vektörleri adı verilir.




Şekil 2.29: Destek Vektör Makinesi, Marjin ve Destek Vektörleri.

Lineer SVM ayırıcı;

$$k(x, y) = x^T y + c \quad (2.14)$$

olarak açıklanmaktadır.

Bununla birlikte gerçek hayatta birçok veri seti böyle bir ayrıma tabi tutulamaz. Gerek veri setinin fazlalığı gerekse de karmaşıklığı lineer ayrımı geçersiz kılabilir. Bu durumda ise yapılması gerekeni SVM çekirdekler (kernel) yolu ile yapmaktadır (Ayhan, 2014). Lineer çekirdeğin yanı sıra sigmoid, polinomial ve RBF çekirdekleri de bulunmaktadır. Bu çalışmada RBF çekirdeği kullanılmıştır.



Şekil 2.30: RBF Temelli Sınıflandırıcı Uygulaması.

Gauss temelli bir çekirdek olan RBF formülü aşağıdaki gibidir.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\alpha^2}\right) \quad (2.15)$$


RBF çekirdeğinin kullanılmasına karar verilmesinden sonra sıra parametrelerin seçimine gelmektedir. Belirleyici etkiye sahip C ve Gama parametreleri doğruluk üzerinde ciddi etkilere neden olmaktadır. C parametresi marjinin genişliğini (C değeri yükselirse marjin daralır ve yanlış sınıflandırma oranı düşer) belirlerken Gama tek bir örneğin etkisinin ne kadar mesafeye ulaştığını gösterir. Yüksek Gama değeri ile olası hyperplane'e yakın noktalar değerlendirmeye alınırken düşük gama değeri ile uzak noktalar da değerlendirmeye alınır (Vapnik, 1995).

2.8 Veri Artırma

Veri artırma (Augmentation) işlemi özellikle veri setinin nispeten küçük olduğu durumlarda büyük yararlar sağlamaktadır (Inoue, 2018). Bu çalışmada kullanılan veri seti Bölüm 2.1’de anlatılan çeşitli kısıtlamalardan dolayı benzerlerine oranla daha küçük ölçekte kalmıştır. Bu nedenle veri artırımına gidilerek başarıya olan etkisi de çalışmanın inceleme alanlarına dahil edilmiştir.

İki çeşit veri artırma yöntemi bulunmaktadır. Bunlardan ilki var olan örnekler üzerinde çeşitli işlemler yapılarak elde edilen yeni örnekler olurken, bir diğeri ise yapay olarak üretilen örneklerin veri setine eklenmesidir (Wong, 2016). Bu çalışmadan ilk yöntem uygulanmıştır.

Veri artırma işlemine yönelik YTKG sınıfı TCG KUMKALE (P-1203)’a ait elde edilen imgeler aşağıda olduğu gibidir.



Şekil 2.31: TCG KUMKALE(P-1203)’ye Ait Veri Arttırma İşlemi Sonucu Elde Edilen İmgeler.

Keras kütüphanesinde yer alan Image Data Generator algoritması ile veri artırma işlemi uygulandıktan sonra veri setinde bulunan 1172 imgenin sayısı 8844'e yükselmiştir. Bu çalışmada algorithmada yer alan rotation_range width_shift_range, height_shift_range, shear_range, zoom_range, channel_shift_range, horizontal_flip değerleri üzerinde değişiklikler yapılarak yeni imgeler üretilmiştir. Veri artırımında dikkat edilmesi gereken iki nokta bulunmaktadır. Öncelikle veri artırımı maliyet üzerinde önemli etkilere sahiptir. Bu çalışmada da deney süresi oldukça uzamıştır ancak artırım sonrasında bile nispeten küçük kalan (8844 imge) veri seti boyu nedeniyle kabul edilebilir seviyede kalmıştır. Eğer veri seti 10 bin imgeden 100 bin imge civarına artırılmış olsaydı bu değişimin dakikalar süren eğitim süresinden saatlere geçileceği göz önünde bulundurulmalıdır. Değerlendirilmeye alınması gereken ikinci konu ise veri artırımına gidilirken parametrelerin hangi oranda değiştirileceğidir. Kullanılan farklı oranlar deney sonucu üzerinde farklı etkilere neden olabilmektedir.

Veri artırımına yönelik deney sonuçları 3.Bölümde açıklanmıştır.

3. DENEYLER

2.1.1 Veri Madenciliği kısmında ayrıntılarıyla ele alınan açık kaynaklardan elde edilen verilerin düzenlenmesinden ve veri önışleme kısmının tamamlanmasının ardından deney safhasına geçilmiştir. Bu safhada cevap bulunması gereken ilk soru hangi filtre ve/veya filtrelerin kullanılması gerektiği olmuştur.

Bu çalışmada, alçak ve yüksek geçirgen olarak ikiye ayrılan filtrelerden alçak geçirgen olarak Gauss filtresi uygulanırken yüksek geçirgen filtre olarak Sobel, Prewitt ve Scharr filtreleri uygulanmıştır. Bunun yanı sıra herhangi bir filtrenin kullanılmadığı durum ile alçak ve yüksek geçirgen filtrelerin birlikte kullanılmalarının çalışma üzerine etkileri de araştırılmıştır.

Tablo 3.1:Filtre Uygulamalarının Veri Seti Üzerindeki Etkileri.

Uygulanan Filtre	Başarı	Standart Sapma
Filtresiz	0,8191	0,0169
Scharr	0,8250	0,0181
Sobel	0,8246	0,0192
Prewitt	0,8238	0,0194
Gauss	0,8336	0,020
Scharr+Gauss	0,8246	0,0166
Sobel+Gauss	0,8251	0,0165
Prewitt+Gauss	0,8238	0,0187
Gauss+Scharr	0,8340	0,0162
Gauss+Sobel	0,8336	0,0178
Gauss+Prewitt	0,8327	0,0185

Tablodan görüleceği üzere en yüksek başarı sırasıyla Gauss+Scharr filtresinin uygulanması ile elde edilmiştir. Herhangi bir filtrenin uygulanmaması ile uygulanması arasındaki fark başarı üzerinde yaklaşık olarak %1,5 civarında olumlu bir etkiye neden olmuştur. Her ne kadar Gauss filtresinin uygulanması ile Gauss+Scharr filtrelerinin birlikte uygulanması arasında ciddi bir fark oluşmasa da standart sapmanın 0,020 seviyesinden 0,016 seviyelerine düşmesi bu tercihe neden olmuştur. Alçak geçirgen ve yüksek geçirgen filtrelerin füzyon işlemi öznitelik vektörlerinin çıkarılmasıyla birlikte deneyimlenmiştir.

Filtreleme işleminin tamamlanmasının ardından öznitelik vektörlerinin elde edilmesine geçilmiştir. Bu safhada Bölüm 3.3'te ayrıntılarıyla belirtildiği üzere Yönelimli Eğrilerin Histogramı (Histogram of Oriented Gradient-HOG) ile Yerel İkili Örüntü (Local Binary Pattern-LBP) algoritmaları kullanılmıştır.

HOG öznitelik vektörlerinin nasıl hesaplandığı Eşitlik 2.3'te verilmiştir. Bölüm 2.3'te de anlatıldığı gibi HOG öznitelik vektörleri hesaplanırken belirlenmesi gereken bazı parametreler vardır. Bunlar blok boyutları, hücre boyutları, oryantasyon ayrıntıları ve normalizasyon değerleridir. Öznitelikleri çıkarılacak imge özelliklerine göre değişiklik gösteren bu parametreler daha detaylı bilgilerin gerektirdiği yaya tespiti gibi durumlarda olabildiğince küçük seçilirken söz konusu ayrıntıların daha kapsamlı olduğu durumlarda büyük ölçeklerin tercih edilmesi gerekmektedir. Bunun nedeni ise yalnızca zamandan tasarruf olmayıp aynı zamanda doğruluk üzerine de doğrudan etki etmesidir. Aşağıda aynı imgeye ait farklı parametrelerle elde edilmiş öznitelik vektörlerinin çıkarımı gösterilmektedir.



Şekil 3.1: ADA Sınıfı Korvete Ait 4x4 Blok Boyutunda ve 32x32 Hücre Boyutunda Çıkartılan Öznitelik Vektörleri.



Şekil 3.2: ADA Sınıfı Korvete Ait 4x4 Blok Boyutunda ve 16x16 Hücre Boyutunda Çıkartılan Öznitelik Vektörleri.

Bu imgede TCG HEYBELİADA korvetine ait bir imgenin 4x4 blok ve 32x32 hücre boyutunda elde edilen öznitelik vektörleri görülmektedir. Bir başka deyişle 32x32 pikselden oluşturulan her bir hücre 4x4 hücreden oluşturulan blokların üzer üzer üst üste binmesiyle normalize edilmiştir. Bununla birlikte burada 9 oryantasyon ayrıntısı seçilmiştir. Yani her bir kar tanesi dokuz yönelimli egriden oluşmaktadır. Bu

yönelimler piksel değerlerinin değişikliğini göstermektedir. Eşitlik 2.3'ten yararlanılarak

$$HOG = \left(\frac{I_x}{C_x} - (B_x - 1) \right) \left(\frac{I_y}{C_y} - (B_y - 1) \right) B_x B_y O \quad (2.16a)$$

$$= \left(\frac{778}{32} - (4 - 1) \right) \left(\frac{403}{32} - (4 - 1) \right) 4x4x9 \quad (2.16b)$$

$$= (24 - 3)(12 - 3)4x4x9 \quad (2.16c)$$

$$= 27.216 \quad (2.16ç)$$

Öznitelik vektörü elde edilmiştir. Daha fazla ayrıntı yakalamak amacıyla hücre ve blok boyutları düşürüldüğünde Şekil: elde edilmiştir.



Şekil 3.3: ADA Sınıfı Korvete Ait 2x2 Blok Boyutunda ve 8x8 Hücre Boyutunda Çıkartılan Öznitelik Vektörleri.


Bu durumda ise elde edilen öznitelik vektörü sayısı 169.344 olmuştur. Bu durum işlem süresinin ve maliyetinin çok fazla uzamasının yanı sıra işlem yapılmak istenen imge dışında kalan birçok öznitelik vektörünün de değerlendirmeye alınmasına ve doğruluk oranının fazlasıyla düşmesine yol açmaktadır.

Bu çalışmada öznitelik vektörlerinin çıkarımı aşamasında kullanılacak parametreleri belirlemek amacıyla binin üzerinde deney yapılmıştır. Yapılan deneylerden doğruluk oranları temel alınarak, en iyi blok, hücre ve imge boyutu kombinasyonu araştırılmıştır.

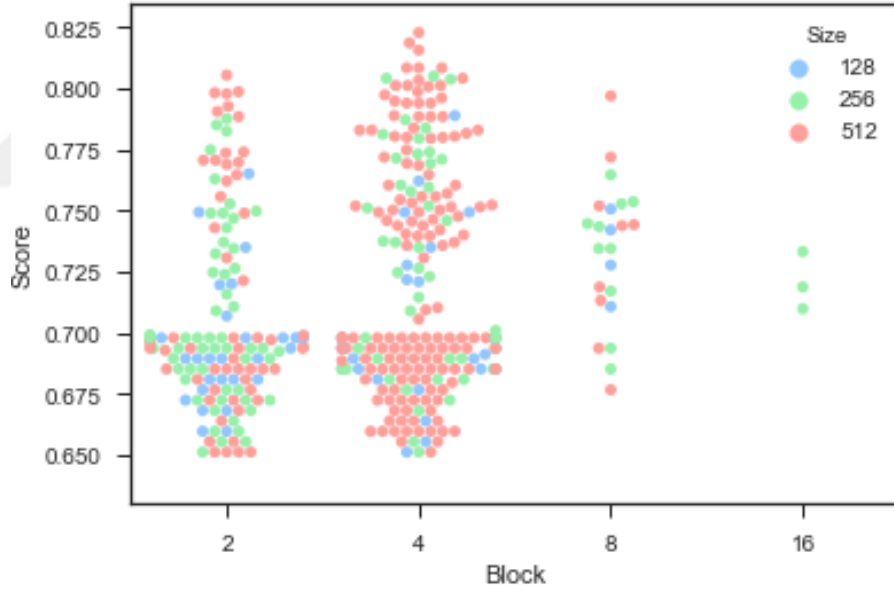
Kombinasyon araştırılırken sezgisel yöntem uygulanmış ve yaklaşık 1100 deney yeterli olarak değerlendirilmiştir. Bu sayede tüm deneylerin yapılması işleminden uzak kalınmıştır. Eğer tüm deneyler yapılmış olsaydı En x Boy tespiti için (32,64,128,256,512 ve kombinasyonları olmak üzere) 25 deney, yönelim eğrilerinin tespiti için (3, 6, 8, 9, 12) 5, blok tespiti için (2, 4, 8, 16, 32) 5, hücre tespiti için (2, 4, 8, 16, 32, 64) 5 olmak üzere toplamda $5^5 = 3125$ ve ayrıca SVM'de parametre tespiti amacıyla C (1, 10, 100, 1000) için 4, gamma (0,001, 0,01, 0,1, 1, default, scale) için 6, kernel (linear, rbf, poly, sigmoid, precomputed) için 5 deney olmak üzere toplamda 120 deney yapılmak durumunda kalınacaktı ve dahası temel bileşenlerin tespitini de bu deneye eklediğimiz zaman iş başlı başına bir sorun oluşturacaktı. Çünkü temel bileşen sayısı RBF çekirdeği için 78 iken linear çekirdeği için 800 olarak elde edilmiştir. Ayrıca çekirdeklerin farklı imge boyutlarına farklı tepkiler verdiği göz önüne alındığında tam doğru deney sayısı yukarıda belirtilen rakamların toplamı değil çarpımına eşit olacaktır. Bu çalışmada yapılan sezgisel yaklaşım ile söz konusu deney sayısı yaklaşık 1100 ile sınırlandırılabilmiştir.

Yazılan algoritma ile elde edilen değer, o ana kadar elde edilen en iyi değerden daha iyi olduğu zamanlarda parametre içerisindeki arama deneylerine devam edilmiştir, daha kötü olduğu durumlarda ise rasgele ($inx=randi(int,int)$) bir değere sıçrama yapılarak deneye kalınan yerden devam edilmiştir.

Deneysel Sonuçların swarm plotları Şekil 3.44 ve Şekil 3.55'te gösterilmiştir.



Şekil 3.4: HOG Çıkarımında Hücre Boyutlarını Belirleme Deneyleri Sonuçlarının Dağılımı.



Şekil 3.5: HOG Çıkarımında Blok Boyutlarını Belirleme Deneyleri Sonuçlarının Dağılımı.

Deney sonuçları da yukarıda anlatılanlar destekler nitelikte olmuş ve en iyi parametreler olarak $C_{x,y}=32$ ve $B_{x,y}=4$ belirlenmiştir.

Şekil 'te hücre boyutu ile resim boyutu ilişkisi sunulmuştur. Hücre boyutu olarak 8×8 seçildiği durumda sonuçların hemen hepsi %75 doğruluk oranının altında kalmıştır.

Bunun nedeninin ise öznitelik vektörlerinin bir kısmının arka plandan kaynaklı gereksiz verilerden çıkarılması ve bunlar üzerinden yorum yapılmaya çalışılmasıdır. Yine görüldüğü gibi hücre boyutu 64 x 64 yapıldığı zaman imge içerisindeki obje üzerinde çok fazla veri kaybı oluşması nedeniyle en yüksek doğruluk oranı olarak %71 elde edilmiştir. Bu nedenlerden dolayı hücre boyutu olarak 32 x 32 seçilmiştir. Benzer şekilde , Sekil 'te blok boyutu ile resim boyutu arasındaki ilişki gösterilmiştir. 4 x 4 blok boyutunun 2 x 2'ye oranla daha iyi sonuç vermesinin temel nedeni ayrıntılarda yaşanan kayıplara karşın normalizasyonun daha iyi yapılmış olmasından ileri gelmiştir. Boyut arttıkça normalizasyon daha iyi yapılmış olsa da bu kez ayrıntılarda oluşan kayıplar doğruluk oranı üzerinde ciddi olumsuz etkilere neden olmuştur.

Yapılan deneylerde imge boyutları da araştırılmış ve önışleme aşaması için belirleyici nitelikte olarak 512x512 imge boyutunun en yüksek doğruluk oranını verdiği görülmüştür. İmge boyutları arttıkça öznitelik vektörleri yine önemli ölçüde artmakta, imge boyutu azaldıkça ise doğruluk üzerinde olumlu etkiler yaratacak önemli veri kayıpları oluşmaktadır.

Çalışmada yalnızca HOG üzerinden deneyler yapılmamış aynı zamanda Yerel İkili Örüntü (LBP) de deneyimlenmiştir.

LBP ile yapılan deneylerde başarılı sonuçlar elde edilememiştir. Python progama dilinde Skimage kütüphanesi kullanılarak yapılan deneylerin sonucunda başarı oranı %32'de kalmış ve farklı sınıflara ait tüm imgelerin deneyler sonucunda yalnızca MEKO sınıfının değerlendirilmesine tabi tutulduğu, deney sonucunda elde edilen ısı haritalarında gözlenmiştir. Bunun temel nedeninin ise gemi imgelerinin imge bütününde merkezde ve büyük alan kaplamasından, bununla birlikte geri kalan bölgelerde de çok çeşitli arka fon ve gürültülerin bulunmasından kaynaklandığı değerlendirilmektedir. LBP algoritması genel olarak yüz tanımda ve bunun yanı sıra doku sınıflandırmada başarılı bir şekilde kullanılmaktadır. Sözü edilen örneklerde küçük ayrıntılar farklı sınıflandırmalara neden olurken savaş gemisi sınıflandırmada bu durumdan söz edilememektedir. Savaş gemilerine ait imgeler incelendiğinde değişikliklerin genelde baş top, ana direkler ve helikopter platformu gibi büyük alanlarda küçük biçimlerde olduğu görülmektedir. Bu durumun LBP üzerinde olumsuz etkiler yarattığı değerlendirilmektedir.

Bununla birlikte LBP temelli olan TPLBP ve FPLBP algoritmaları ile yapılan sınıflandırmada %75'in üzerinde başarı elde edilmiştir. TPLBP ve FPLBP algoritmalarının LBP'de olduğu gibi yalnızca komşu pikselleri değil aynı zamanda komşu blokları da değerlendirmeye dahil etmektedir. Bu nedenle gemi imgeleri üzerinde nispeten daha geniş bölgeye yayılan ayırt edici öznelikler daha belirgin hale gelmektedir. TPLBP ve FPLBP öznelikleri MATLAB programlama dili kullanılarak elde edilmiştir. Daha sonra tüm değerlendirme yine Python ile yapılmıştır.

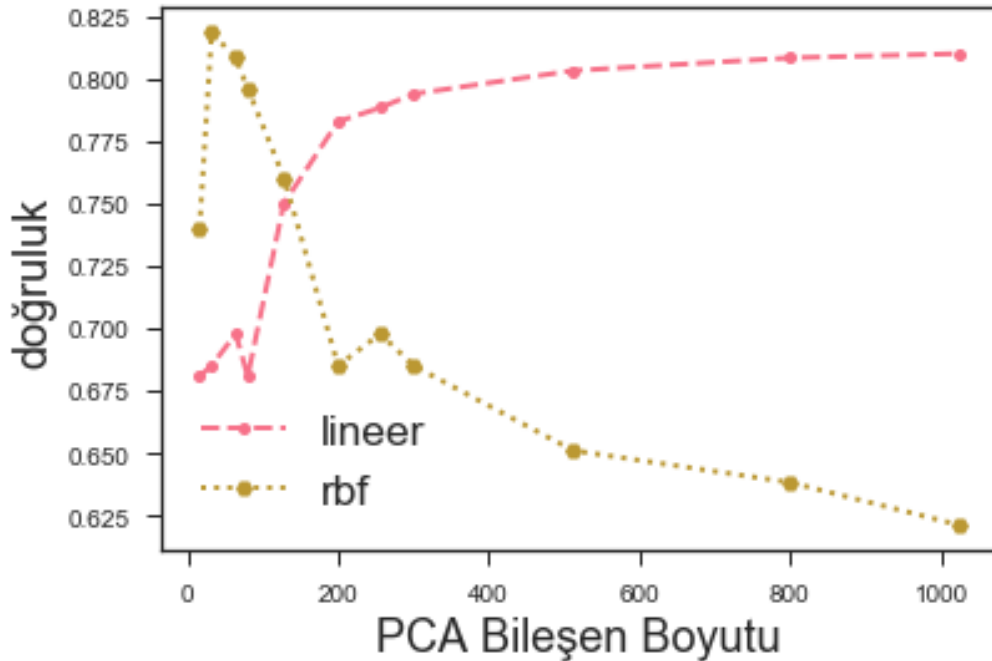
Rasgele olarak seçilen 10 deneye ait veriler aşağıdaki tablo sunulmuştur.

Tablo 3.2: TPLBP ve FPLBP Deney Sonuçları.

DENEY	TPLBP		FPLBP	
	LPF	HPF	LPF	HPF
1	0,8170	0,7829	0,7361	0,7872
2	0,7660	0,7787	0,6851	0,7447
3	0,8255	0,7830	0,7532	0,7489
4	0,7787	0,7319	0,7191	0,7489
5	0,7872	0,7361	0,6936	0,7064
6	0,8043	0,7915	0,7489	0,7277
7	0,7957	0,7532	0,7191	0,7234
8	0,7702	0,7447	0,7021	0,7447
9	0,8383	0,7872	0,7617	0,8
10	0,7872	0,7489	0,7063	0,7106
ORT.	0,7970	0,7638	0,7225	0,7442
σ	0,0227	0,0218	0,0250	0,0287

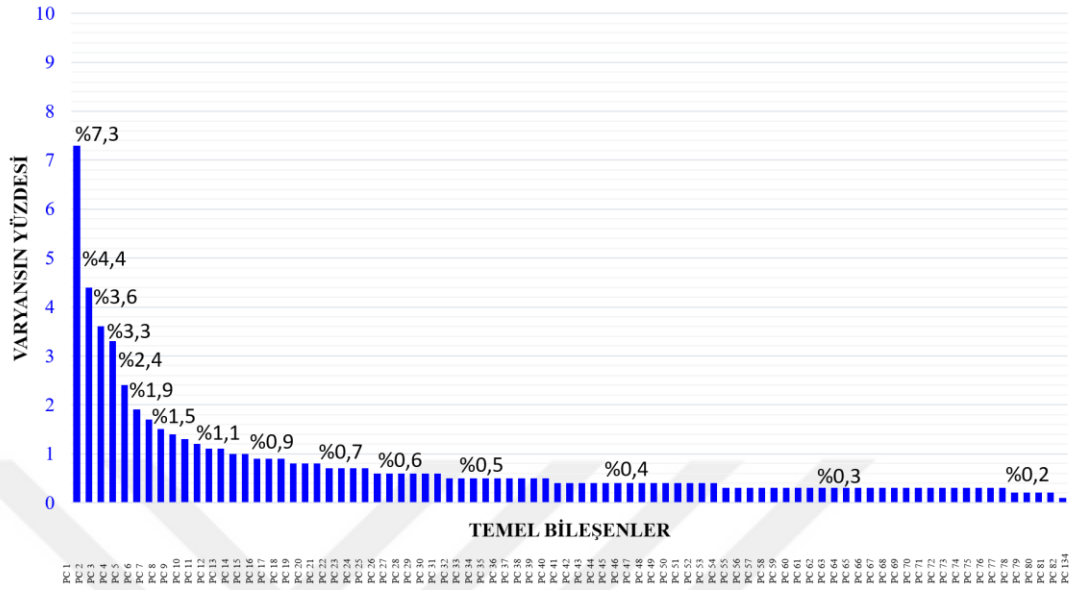
Yapılan deneylerin tamamında TPLBP ile FPLBP'ye oranla daha başarılı sonuçlar edilirken büyük çoğunluğunda düşük geçirgenli filtrelerin doğruluk oranları daha yüksek çıkmıştır. Deney sonuçlarının bu şekilde elde edilmesinin arkasında yatan temel neden olarak TPBLP'nin FPLBP'ye oranla ayrıntılara daha fazla odaklanabiliyor olması değerlendirilmektedir. Bu durum nedenleri Şekil 2.22: TPLBP Hesaplama Modeli ($S=8, w=3, \alpha=2$) ve Şekil 2.24: FPLBP Hesaplama Modeli de açıklanmıştır.

Öznelik vektörlerinin elde edilmesinden sonra Bölüm 2.4'te söz edildiği gibi normalizasyon yapılmış ve boyut azaltma işlemine geçilmiştir. Boyut azaltmada yukarıda söz edildiği gibi amaç bir yandan doğruluk oranını artırırken bir yandan da işlem hızınızı yükseltmek ve maliyeti en aza indirmektedir. Burada dikkat edilmesi gereken konu ise boyut azaltırken önemli veri kayıplarına neden olmamak ama aynı zamanda mümkün olan en az boyutu kullanmaktır. Bu çalışmada yapılan deneyler sonucunda aşağıda verilen tabloda da görüldüğü gibi HOG öznelik vektörleri sınanırken RBF çekirdeği kullanıldığından PC boyutu olarak 80, TPBLP ve FPBLP uygulanırken LINEAR çekirdek kullanıldığından 800 olarak elde edilmiştir.



Şekil 3.6: Çekirdek ile PCA Bileşeni Etkisi. RBF Çekirdek Düşük Boyutlarda Daha İyi Başarım Gösterirken, Lineer Modelde Bu Durum Tam Terstir.

Bu durum yalnızca deneylerle elde edilmemiş ve HOG öznelik vektörleri bulunduğundan sonra Python’da Numpy kütüphanesi kullanılarak da gerçekleştirilmiştir. Elde edilen sonuçlar aşağıdaki grafikte olduğu gibidir.



Şekil 3.7: Temel Bileşenlerin (PC) Varyans Dağılımları ve Etkileri. İlk 78 PC %0,3 ve Daha Yüksek Etkiye Sahipken Varyans Değişikliği PC83 ile Birlikte %0,1’e Düşmektedir.

Bu grafikte açıkça görülebildiği gibi PC1’in Varyans değişikliği ve çalışma üzerine etkisi %7,3’tür. PC2 ile birlikte (%4,4) ile azalan varyans değişikliği PC16 ile %1,0’in altına düşmekte ve PC83’ile birlikte %0,1 olmuştur. Bu nedenle ilk PC78 ve önceki temel bileşenler doğruluk üzerinde olumlu ve yeterli etkiyi sağlamıştır ve %83,44 ve $\sigma = 0,0162$ değerlerine ulaşılmıştır. Bu esnada deney süresi olarak **2:15,58** ölçülmüştür. Temel Bileşen Boyutu 54 seçildiğinde (%0,4 ve yukarısı) Doğruluk Oranı olarak %82,5957 elde edilirken $\sigma = 0,02484$ olarak ölçülmüş, PC = 40 seçildiğinde (%0,5 ve yukarısı) %81,5744 ve $\sigma = 0,02437$, PC = 15 seçildiği durumda ise (%1,0 ve yukarısı) %69,0212 ve $\sigma = 0,02420$ değerleri elde edilmiş ve bu işlem **1:54,50**’de tamamlanmıştır. Süre açısından büyük bir değişiklik olmamasının temel nedeni ise veri setinin küçüklüğünden kaynaklanmaktadır. Ciddi bir değişiklik olmamasından dolayı da deneylerde elde edilen en iyi sonuç olarak PC = 78 değeri temel alınmıştır.

Bölüm 2.8’de açıklandığı gibi bu çalışmada veri artırma işlemi uygulanmış ve veri setinde yer alan 1172 imge 8844’e çıkartılmıştır. Veri seti artırıldıktan sonra HOG ile

elde edilen öznitelik vektörleri yeniden test edilmiş Doğruluk Oranı %83,40'tan yaklaşık %1,5'luk bir artışla %85.1063'e ulaşılmıştır. Veri setinin artması nedeniyle maliyet artmış değerlendirme süresi 2:15,58'ten 25:40,38'e yükselmiştir.

Veri artırma işlemi sırasında kullanılan Image Data Generator'a ait (rotation_range=10, width_shift_range=[-1,0,1], height_shift_range=10, shear_range=0.25, zoom_range=0.2, channel_shift_range=10., horizontal_flip=True) parametrelerdeki değişiklikler de sonuç üzerinde farklı etkilere neden olmaktadır.

Boyut azaltma işleminin de tamamlanmasının ardından sınıflandırma algoritmasının uygulamasına geçilmiştir. Bölüm 2.7'de açıklandığı üzere sınıflandırma algoritması olarak Destek Vektör Makinesi (SVM-Support Vector Machine) kullanılmıştır. Yapılan deneylerin sonucunda RBF çekirdeği düşük sayıda Temel Bileşenler (78) ile yüksek değerler verirken Lineer çekirdeği yüksek sayılarda Temel Bileşenler (800) ile daha olumlu sonuçlar vermiştir. Bunun nedeninin ise çok yoğun, karmaşık ve birbirine çok benzeyen imgelerde bile RBF çekirdeğinin düşük sayıdaki Temel Bileşenler ile daha iyi açıklanması olarak değerlendirilmektedir. SVM ile RBF çekirdeği kullanılırken $C = 100$, $\gamma = 0.05$, decision function shape = 'ovo'(One vs One) parametreleri en iyi sonuçları vermiştir. Örnek parametrelere ilişkin sonuçlar Tablo 3.3: C ve Gama Parametrelerinin Veri Seti Üzerindeki Etkileri'te verilmiştir.

Tablo 3.3: C ve Gama Parametrelerinin Veri Seti Üzerindeki Etkileri.

	$\gamma = 0,1$	$\gamma = 0,01$	$\gamma = 0,001$	$\gamma = 0,05$
C = 1	%75,8723	%70,4255	%48,5532	%78,8510
C = 10	%79,3191	%80,5957	%71,3191	%83,1914
C = 100	%79,3617	%80,0425	%77,7446	%83,5744

SVM'de kullanılacak parametrelerin bulunmasından sonra test seti değerlendirmeye tabi tutulmuştur. Değerlendirmeden sonra elde edilen veriler ile iki basamaklı füzyon (FF-Full Fusion) işlemi gerçekleştirilmiştir. İki farklı sınıflandırıcı olan SVM ve LBP

sınıflandırıcılarından alçak ve yüksek geçirgenli filtre değerlerinden elde edilen veriler füzyon uygulanarak yeniden değerlendirilmiştir.

Elde edilen veriler aşağıdaki tablo sunulmuştur.

Tablo 3.4: İki Basamaklı Füzyon Uygulanması Sonucu Elde Edilen Veriler.

DENEY	LBP		LBP FUSION	HOG		HOG FUSION	FULL FUSION
	LPF	HPF		LPF	HPF		
1	0,817	0,7829	0,8553	0,8468	0,8383	0,834	0,8511
2	0,766	0,7787	0,8043	0,8426	0,8255	0,8638	0,8596
3	0,8255	0,783	0,8468	0,8213	0,817	0,8383	0,8596
4	0,7787	0,7319	0,8085	0,8127	0,8127	0,8043	0,8383
5	0,7872	0,7362	0,8128	0,817	0,8128	0,8213	0,8213
6	0,8043	0,7915	0,834	0,8511	0,8298	0,8553	0,8553
7	0,7957	0,7531	0,8511	0,8212	0,817	0,8383	0,8638
8	0,7702	0,7447	0,8468	0,817	0,8043	0,8298	0,8511
9	0,8383	0,7872	0,8723	0,8809	0,8723	0,8894	0,8936
10	0,7872	0,7489	0,8	0,8255	0,8213	0,834	0,8298
ORT.	0,797	0,7638	0,8328	0,8336	0,8251	0,8426	0,8506

Yukarıdaki tablodan da net olarak görülebildiği gibi Füzyon her seferinde daha iyi bir sonuç vermiş ve doğruluk üzerinde %2,56'ya varan bir iyileştirme sağlanmıştır. Zaman zaman ikinci basamak füzyon olarak adlandırdığımız Tam Füzyon diğer değerlerin altında kalsa da daha başarılı olan değer ilk basamak füzyon olmuştur.

Bununla birlikte genel ortalamada, şimdiye kadar ortalamada elde edilen en iyi değer olan HOG_LP(%83,36) ve HOG_LHP(%83,40)'den %1,66 oranında daha yüksek bir başarı elde edilmiştir.

Yukarıda açıklanan iki basamaklı füzyona (Full Fusion) ek olarak füzyonun başarısını test etmek amacıyla TPLBP ve FPLBP arasında da füzyon uygulanmıştır. Uygulanan füzyon ve elde edilen sonuçlar aşağıdaki tabloda sunulmuştur.

Tablo 3.5: TPLBP ve FPLBP Algoritmalarının LP ve HP Filtre ile İki Basamaklı Füzyon Uygulaması Sonuçları.

DENEY	ALÇAK GEÇİRGEN FİLTRE		FUSION (1)	YÜKSEK GEÇİRGEN FİLTRE		FUSION (2)	FULL FUSION (1⊕2)
	TPLBP	FPLBP		TPLBP	FPLBP		
1	0,8170	0,7361	0,8127	0,7829	0,7872	0,7957	0,8425
2	0,7660	0,6851	0,7830	0,7787	0,7447	0,7574	0,8085
3	0,8255	0,7532	0,8383	0,7830	0,7489	0,7745	0,8468
4	0,7787	0,7191	0,8298	0,7319	0,7489	0,7617	0,8213
5	0,7872	0,6936	0,7872	0,7361	0,7064	0,7447	0,8128
6	0,8043	0,7489	0,8298	0,7915	0,7277	0,7787	0,8298
7	0,7957	0,7191	0,8383	0,7532	0,7234	0,7489	0,8340
8	0,7702	0,7021	0,8212	0,7447	0,7447	0,7532	0,8214
9	0,8383	0,7617	0,8553	0,7872	0,80	0,7872	0,8553
10	0,7872	0,7063	0,7957	0,7489	0,7106	0,7361	0,80
σ	0,0227	0,0250	0,0227	0,0218	0,0287	0,0184	0,0168

Tablo 3.5-devam

ORT	0,7970	0,7225	0,8191	0,7638	0,7442	0,7638	0,8227
-----	--------	--------	--------	--------	--------	--------	---------------

Bu tablodan da net olarak görüldüğü gibi füzyon başarı oranı üzerinde önemli etkiler yaratabilmektedir. Bu olumlu etkiler bu çalışmada %2,98'e kadar ulaşmıştır. Yalnızca iki deneyde Tam Füzyon diğer başarı değerlerinin altında kalmış ama bu değer birinci basamak füzyona ait olmuş ve hiçbir ikinci basamak füzyon yapılmamış değerlerin altında kalmamıştır. Bu da füzyonun başarısını net olarak ortaya koymuştur.



4. TARTIŞMA VE SONUÇ

4.1 Veri Setinin Katkıları

Bu çalışma ile açık kaynaklardan elde edilen Türk Deniz Kuvvetleri Envanterinde bulunan 60 parça gemiye ait (8 Meko sınıfı Fırkateyn, 8 Gabya sınıfı fırkateyn, 3 Ada sınıfı korvet, 6 Burak sınıfı Korvet, 19 Hücumbot (Doğan, Rüzgar, Yıldız ve Kılıç sınıfları), 16 YTKG) 1172 imgeden oluşan bir veri seti literatüre kazandırılmıştır.

4.2 Füzyonun Katkıları

Çalışmanın en önemli katkılarından birisi olan sınıflandırma sonrası uygulanan iki basamaklı füzyon işleminin doğrulama üzerinde %1,66'dan %5,89'a kadar olumlu etki yarattığı gözlemlenmiştir. Bu açıdan bakıldığında elde edilen en yüksek değerler birinci veya ikinci basamak füzyon sonrası elde edilen değerlerdir. Söz konusu değerler Tablo 3.4 ve Tablo 3.5'te görülmektedir.

4.3 Veri Artırmanın Katkıları

Çalışmanın bir diğer katkısı olan veri artırma görece küçük veri setinden dolayı uygulanmış ve eldeki 1172 kullanılabilir durumda olan imge sayısı 8844'e artırılmıştır. Veri artırma sonrası uygulanan deneylerde başarı oranının %1,5 oranında arttığı gözlemlenmiştir.

4.4 Sonuçlar

Tanımlanmış Deniz Resminin etkin olarak oluşturulması ve idamesi tespit, teşhis ve kimliklendirmeye doğrudan ilişkilidir. Savaş gemileri imgelerinin otomatik olarak sınıflandırılması TDR'nin saptanması ve muhafazası açısından olumlu etkiler sağlamaktadır. Bu sayede;

1. Olası personel hatalarının önüne geçilerek hata olasılığının net olarak bilinir hale getirilmesi sağlanmıştır.
2. Özellikle kara suları sorunu yaşanan denizlerde kara suyuna yakın seyreden bir temasın tam olarak kimliklendirilememesi sorunu yaşanmaktadır. Bu sorun yeterli

ölçekte bir imge elde edilebilmesiyle ortadan kaldırılabılır hale getirilmiştir.

3. Elektronik destek birimleri olmayan gemilerin (şu an için yakın sularda keşif karakol yapan Yeni Tip Karakol Gemilerinde elektronik destek sistemi bulunmamaktadır.) görece uzak mesafelerden (bu mesafe söz konusu gemiler için hali hazırda göz mesafesiyle kısıtlıdır) yüksek doğrulukla kimliklendirilebilmesi sağlanmıştır.

4.5 Tartışma ve Öneriler

1. Bu çalışmada Şekil 2. 1'de gösterilen işlemler yapılmış, veri setinin görece küçük olmasından dolayı yapay sinir ağları kullanılmamıştır. Gelecekteki çalışmalarda bu konunun denenmesinin yararlı olacağı değerlendirilmektedir.

2. Bunun yanı sıra başarı oranı tatmin eder bir seviyeye ulaşmış olsa da eğitim setine eklenecek sentetik verilerin başarı oranını daha da yukarı seviyelere çekeceği değerlendirilmektedir.

3. Açık kaynaklardan alınan veriler yerine özellikle sınıflandırmaya yönelik olarak elde edilecek verilerin (arka fon gürültülerinden uzak, gemi bütünü olduğu gibi içerecek, yüksek çözünürlükte, doğru açılardan alınmış, vb.) başarıya olumlu katkılar sağlayacağı değerlendirilmektedir.



KAYNAKÇA

- Ahonen, T. H. "Face Recognition with Local Binary Patterns". *European conference on computer vision* Springer. Berlin. Heidelberg (2004): 469-481.
- Alpaydın, E. *Yapay Öğrenme*. İstanbul: Boğaziçi Üniversitesi Yayınevi (2012).
- Alves, J. A. "Recognition of Ship Types from An Infrared Image Using Moment Invariants and Neural Network" (Yüksek Lisans Tezi). *Naval Postgraduate School, MONTEREY CA* (2001).
- Avcı, K. A. "Keman ve Viyola Çalgı Seslerinin Aynı Notalar için Makine Öğrenme Tabanlı Sınıflandırılması". *2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE.* (2018): 1-4.
- Ayhan, S. &. "Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü için Çekirdek Fonksiyonu Seçimi". *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi. c. 9. s. 1.* (2014): 175-201.
- Bentes, C. V. "Ship Classification in Terrasar-X Images With Convolutional Neural Networks". *Journal of Oceanic Engineering. c. 43. s. 1.* (2017): 258-266.
- Bhanu, B. "Automatic Target Recognition: State of the Art Survey". *Transaction on Aerospace and Electronic Systems c. 22. s. 4.* (1986): 364-379.
- Burt, P. &. "The Laplacian Pyramid as a Compact Image Code". *Transactions on communications. Dallas. IEEE. c. 31 s. 4.* (1983): 532-540.
- Büyüköztürk, Ş. *Sosyal Bilimler için Veri ve Analizi El Kitabı: İstatistik, Araştırma Deseni, SPSS Uygulamaları ve Yorum*". Pegem A Yayıncılık. (2002).
- Chang, C. C. "LIBSVM: A Library for Support Vector Machines". *ACM transactions on intelligent systems and technology (TIST). c. 2. s. 3.* (2011): 27.
- Chuaysi, B. K. "Warship Classification from Distant View Using Dynamic Time Warping and k-NN". *2012 International Workshop pn Smart Info-Media Systems in Asia. SISA.* (2012): 150-155.
- Çerçi, Ç. T. "EMG Sinyallerinin Özniteliklerinin Çıkarılması, YSA ve kNN Algoritmalarıyla sınıflandırılması". *26th Signal Processing and Communications Applications Conference (SIU). IEEE.* (2018): 1-4.
- Dalal, N. T. "Histograms of Oriented Gradients for. Computer Vision and Pattern". IEEE. (2005).
- Deng, G. &. "An Adaptive Gaussian Filter for Noise Reduction and Edge Detection". *IEEE*

- Conference Record Nuclear Science Symposium and Medical Imaging Conference. IEEE. (1993): 1615-1619.*
- Dollar, P. W. "Pedestrian Detection: An Evaluation of the State of the Art". *IEEE Transactions On Pattern Analysis And Machine Intelligence. c. 34 s. 4. (2011): 743-761.*
- Fodor, I. "A Survey of Dimension Reduction Techniques". *US: Lawrence Livermore National Lab., CA (US). (2002).*
- Gąszczak, A. B. "Real-time People and Vehicle Detection from UAV Imagery". *Intelligent Robots and Computer Vision XXVIII : Algorithm and Techniqes. SPIE. (2011): 1-13.*
- Giompapa, S. C. "Naval Target Classification by Fusion of IR and EO Sensors". *Electro-optical and infrared systems. Technology and Applications IV c. 6737. (2007): 67370T.*
- Gündoğdu, E. S. MARVEL: "A Large-Scale Image Dataset for Maritime Vessels". *ACCV 2016. Lecture Notes in Computer Science, (2016): 165-180.*
- Gürkaynak, C. D. "Fine-tuning Convolutional Neural Networks for Maritime Vessel Classification, Verification and Recognition". (Yüksek Lisans Tezi). *Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul. (2018).*
- He, K. S. "Guided Image Filtering". *European conference on computer vision. Berlin: Springer. Berlin. Heidelberg. (2010): 1-14.*
- Heikkilä, M. P. "Description of Interest Regions with Local Binary Patterns". *Pattern recognition. c. 42. s.3. (2009): 425-436.*
- Inoue, H. *arXiv. preprint arXiv:1801.02929.: <https://arxiv.org/abs/1801.02929v2> adresinden alındı.(2018).*
- Kourou, K. E. "Machine Learning Applications in Cancer Prognosis and Prediction". *Computational and structural biotechnology journal. c. 13. (2015): 8-17.*
- Kumlu, D. J. "Autonomous Ship Classification Using Synthetic and Real Color Images". *The International Society for Optical Engineering. SPIE. (2013).*
- Lang, H. Z. "Hierarchical Ship Detection and Recognition with High-Resolution Polarimetric Synthetic Aperture Radar Imagery". *Journal of Applied Remote Sensing. c. 8. s.1. (2014): 1-17.*
- Lang, H. Z. "Ship Classification in SAR Image by Joint Feature and Classifier Selection". *Geoscience and Remote Sensing Letters. c. 13. s. 2. (2015): 212-216.*
- Lee, J. S. "Digital Image Enhancement and Noise Filtering by Use of Local Statistics". *IEEE Transactions on Pattern Analysis & Machine Intelligence c. 2. (1980): 165-168.*

- Liao, S. Z. "Learning Multi-Scale Block Local Binary Patterns for Face Recognition". *International Conference on Biometrics*. Springer. Berlin. Heidelberg. (2007): 828-837.
- Maaten, L. P. "Dimensionality Reduction: A Comparative Review". *J Mach Learn Res*. c. 10. (2009): 66-71.
- Mahfouz S., M.-C. F. "Target Tracking Using Machine Learning and Kalman Filter in Wireless Sensor Networks". *Sensors Journal. Institute of Electrical and Electronics Engineers*. (2014): 3715-3725.
- Mandloi, G. "A Survey on Feature Extraction Techniques For Color Images". *International Journal of Computer Science and Information Technologies*. c. 5. s. 3. (2014): 4615-4620.
- Margarit, G. &. "Ship Classification in Single-Pol SAR Images Based On Fuzzy Logic". *Transactions on Geoscience and Remote Sensing*. c. 49. s. 8. (2011): 3129-3138.
- Minsky, M. "The Emotion Machine: Commonsense Thinking, Artificial Intelligence, and the Future of the Human Mind". Simon and Schuster. (2007).
- Motwani, M. C. "Survey of Image Denoising Techniques". *Proceedings of GSPX*, (2004): 27-30.
- Musman, S. K. "Automatic Recognition of ISAR Ship Images". *IEEE Transactions on Aerospace and Electronic Systems*. c. 32. s. 4. (1996): 1392-1404.
- Oğuzlar, A. "Veri Ön İşleme". *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. s. 21. (2003): 67-76.
- Ojala, T. P. "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. (2002): 971-987.
- Osman, H. M. "Classification of Ships in Airborne SAR imagery Using Backpropagation Neural Networks". *Radar Processing, Technology, and Applications II* c. 3161. (1999): 126-136.
- Palabaş, T. "Serviks Kanseri Verilerinin Sınıflandırılması ve Rastsal Altuzaylar Algoritmasının Sınıflandırma Performansına Etkisi". *2018 26th Signal Processing and Communications Applications Conference (SIU)*. İzmir. IEEE. (2018): 1-4.
- Parkhi, O. M. "Deep Face Recognition". *bmvc* c. 1. s. 3. (2015): 6.
- Picard, R. "Affective Computing". MIT PRESS. Cambridge. (1997).

- Saunders, S. "*Jane's Fighting Ships 2010-2011*" (2011).
- Scharr, H. "Optimal Filters for Extended Optical Flow". *IWCM 2004. Lecture Notes in Computer Science*. Springer. Berlin. Heidelberg. c. 3417. (2007): 14-29
- Schroff, F. K. "Facenet: A Unified Embedding for Face Recognition". *Proc. CVPR*. (2015).
- Solmaz, B. G. "Generic and Attribute-Specific Deep Representations for Maritime Vessels". *IPSJ Transactions on Computer Vision and Applications*. c. 22. (2017).
- Sorzano, C. O. "A survey of Dimensionality Reduction Techniques". <http://arxiv.org/abs/1403.2877> adresinden alındı. (2014).
- Tian, Y. P. "Deeptest: Automated Testing of Deep-Neural-Network-Driven Autonomous Cars". *Proceedings of the 40th international conference on software engineering ICSE*. (2018): 303-314.
- Turing, A. "Computing Machinery and Intelligence". *Mind*, c. LIX. s. 236. (1950): 433-460.
- Türk Deniz Kuvvetleri Komutanlığı*. Dz.K.K.: <https://www.dzkk.tsk.tr/> adresinden alındı. (2019).
- Valin, P. T. "Hierarchical Ship Classifier for Airborne Synthetic Aperture Radar (SAR) Images". *Conference Record of the Thirty-Third Asilomar Conference on Signals, Systems, and Computers*. Pacific Grove, CA, USA: IEEE. (1999): 1230-1234.
- Vapnik, V. "The Nature of Statistical Learning Theory". New York: Springer-Verlag. (1995).
- Watts, A. j. "Jane's Warship Recognition Guide". New York. NY: Collins. (2006).
- Wolf, L. H. "Descriptor Based Methods In The Wild". (2008).
- Wong, S. C. "Understanding Data Augmentation for Classification: When to Warp?". *2016 international conference on digital image computing: techniques and applications (DICTA)*. IEEE. (2016): 1-6.
- Xie, L. T. "Simple Techniques Make Sense: Feature Pooling and Normalization for Image Classification". *IEEE transactions on circuits and systems for video technology*. (2015): 1251-1264.
- Zhang, S. Y. "Occluded Pedestrian Detection Through Guided Attention in CNNs". *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE. (2018): 6995-7003.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KARA, Yavuz Alper
Uyruğu : Türkiye Cumhuriyeti
Doğum tarihi ve yeri : 10.01.1982
Telefon : 5417278085
e-mail : yavuza.kara@gmail.com



Eğitim

Derece	Üniversite ve Bölüm	Mezuniyet tarihi
Yüksek lisans	Milli Savunma Üniversitesi	27.01.2020

Lisans	Deniz Harp Okulu	30.08.2003
--------	------------------	------------

Meslekî Deneyim

Yıl	Yer	Görev
2003-Devam	Dz.K.K.	Deniz Subayı

Yabancı Dil

İngilizce

Yayımları

Kara, Y. A., Uçarer, Ö. K., & Gündoğdu, B. (2019, April). Automatic Warship Recognition System: Dataset, Feature Representation and Classification Analysis. In *2019 27th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Tezden Türetilen Yayımları/Sunumları

Kara, Y. A., Uçarer, Ö. K., & Gündoğdu, B. (2019, April). Automatic Warship Recognition System: Dataset, Feature Representation and Classification Analysis. In *2019 27th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.