

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

**DENİZ HEDEFLERİNİN OTOMATİK OLARAK
SINIFLANDIRILMASINDA SOA YAKLAŞIMININ
KULLANIMI**

BAKİ BATI

KOCAELİ 2021

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

**DENİZ HEDEFLERİNİN OTOMATİK OLARAK
SINIFLANDIRILMASINDA SOA YAKLAŞIMININ
KULLANIMI**

BAKİ BATI

Prof.Dr. Nevcihan DURU

Danışman, Kocaeli Üniv.

Prof.Dr. Hasan OCAK

Jüri Üyesi, Kocaeli Üniv.

Prof.Dr. Şeref SAĞIROĞLU

Jüri Üyesi, Gazi Üniv.

Prof. Dr. İbrahim SOĞUKPINAR

Jüri Üyesi, Gebze Teknik Üniv.

Doç.Dr. Sevinç İlhan OMURCA

Jüri Üyesi, Kocaeli Üniv.

Tezin Savunulduğu Tarih: 17.05.2021

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması kapsamında, x-band radarlar tarafından tespit edilen deniz hedeflerinin otomatik olarak sınıflandırılması için özgün bir füzyon yöntemi geliştirilmiştir. Önerilen yöntem sayesinde başarımların artışı ve otomatik sınıflandırma çalışması için SOA yaklaşımının kullanımı irdelenmiştir.

Tez çalışmamda desteğini esirgemeyen, çalışmalarına yön veren, bana güvenen ve yüreklendiren danışmanım Prof. Dr. Nevcihan DURU'ya sonsuz teşekkürlerimi sunarım.

Akademik çalışmalarım sırasında, birçok aşamada beni destekleyen Bilgisayar Mühendisliği Bölümü araştırma görevlilerine ve Fen Bilimleri Enstitüsü çalışanlarına teşekkür ediyorum.

Doktora öğrenimim boyunca desteklerini esirgemeyen başta Osman KARABAYIR ve Mehmet Zahid KARTAL olmak üzere çok sevgili TÜBİTAK BİLGEM RAPSİM çalışanlarına sonsuz teşekkürler sunarım.

Hayatım boyunca bana güç veren en büyük destekçilerim, her aşamada sıkıntılarımı ve mutluluklarımı paylaşan sevgili babam Fahrettin BATI, annem Hacer BATI, eşim Özge BATI ve kardeşlerim Mehmet Emre BATI ile Fatma BATI'ya sonsuz teşekkürlerimi sunarım.

Son olarak, gelecekte kendilerine ilham kaynağı olmasını ümit ederek bu tezi çocuklarım Elif Nil BATI ve Ege BATI'ya ithaf ediyorum.

Mayıs – 2021

Baki BATI

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
TABLolar DİZİNİ	vi
SİMGELER VE KISALTMALAR DİZİNİ	vii
ÖZET.....	ix
ABSTRACT	xi
GİRİŞ	1
1. HEDEF SINIFLANDIRMA İLE İLGİLİ TEMEL KAVRAMLAR	5
1.1. Ardışıl Menzıl Profılı Sınıflandırma.....	12
2. HEDEF SINIFLANDIRMA KÜTÜPHANESİ.....	18
2.1. Veri Önışleme	18
2.1.1. Anomali giderme.....	18
2.1.2. Veri normalizasyonu	19
2.1.3. Kargaşa giderme.....	20
2.1.4. Öznitelik çıkartımı	24
2.1.5. Öznitelik etki analizi sonuçları	28
2.2. Sınıflandırma Algoritmaları.....	36
2.2.1. Yapay sinir ağları	37
2.2.2. Olasılıksal sinir ağları (PNN).....	39
2.2.3. Konvolüsyonel Sinir Ağları (CNN)	40
2.2.4. YOLO.....	42
2.3. Servis odaklı mimari ile otomatik sınıflandırma kavramsal tasarımı	45
2.3.1. SOA fonksiyonel bileşenleri	48
2.3.2. Web servisleri.....	50
2.3.3. SOA ile merkezi sınıflandırma mimarisi	51
3. ARDIŞIL MENZİL PROFİLİ FÜZYON YÖNTEMİ (AMPF).....	54
4. KULLANILAN VERİ ENVANTERİ.....	60
4.1. Ardışıl Menzıl Profillerinin Sentetik Olarak Elde Edilmesi.....	60
4.2. Ardışıl Menzıl Profillerinin Ölçümsel Olarak Elde Edilmesi.....	66
5. ARDIŞIL MENZİL PROFİLİ SINIFLANDIRMA ALGORİTMASI UYGULAMALARI.....	73
5.1. Sentetik Veri İle Elde Edilen Sınıflandırma Sonuçları	75
5.2. Ölçüme Dayalı Veri İle Elde Edilen Sınıflandırma Sonuçları.....	79
5.2.1. CNN sınıflandırıcı ile elde edilen sınıflandırma sonuçları.....	80
5.2.2. PNN sınıflandırıcı ile elde edilen sınıflandırma sonuçları	84
5.2.3. YOLO V5 sınıflandırıcı ile elde edilen sınıflandırma sonuçları	88
6. SONUÇLAR VE ÖNERİLER	92
KAYNAKLAR	97
KİŞİSEL YAYIN VE ESERLER	105
ÖZGEÇMİŞ	106

ŞEKİLLER DİZİNİ

Şekil 1.1. Çoklu Bakış Açısına Göre Hedef Gösterimleri.....	13
Şekil 2.1. Hız ve bakış açısı öznitelikleri için anomali giderme işlemi	19
Şekil 2.2. Örnek menzil profili verisi	21
Şekil 2.3. NLM Ara değerlendirme yaklaşımı.....	23
Şekil 2.4. Kargaşası giderilmiş menzil profili verisi	24
Şekil 2.5. Tanker sınıfı temsili menzil profili.....	27
Şekil 2.6. Çıkarılan özniteliklerin sınıf bazlı olarak sergilenmesi.....	28
Şekil 2.7. Hedefe ait uzunluk değerinin (normalize) menzil profili kümesi içerisindeki dağılımı	29
Şekil 2.8. Boy özneliğinin hedef tiplerine göre dağılımı	29
Şekil 2.9. Hedefe ait pik noktası mesafesi değerinin (normalize) menzil profili kümesi içerisindeki dağılımı	30
Şekil 2.10. Hedefe ait pik noktası mesafesi değerinin (normalize) hedef tiplerine göre dağılımı	30
Şekil 2.11. Hedefe ait en yüksek iki genlik noktası arasındaki mesafe değerinin (normalize) menzil profili kümesi içerisindeki dağılımı.....	31
Şekil 2.12. Hedefe ait en yüksek iki genlik noktası arasındaki mesafe değerinin (normalize) hedef tiplerine göre dağılımı	31
Şekil 2.13. Hedefe ait yüksek genlikli nokta sayısı değerinin (normalize) menzil profili kümesi içerisindeki dağılımı	32
Şekil 2.14. Hedefe ait yüksek genlikli nokta sayısı değerinin (normalize) hedef tiplerine göre dağılımı	33
Şekil 2.15. Hedefe ait simetri değerinin (normalize) menzil profili kümesi içerisindeki dağılımı.....	33
Şekil 2.16. Hedefe ait simetri değerinin (normalize) hedef tiplerine göre dağılımı.....	34
Şekil 2.17. Hedefe ait yansıtıcılık değerinin (normalize) menzil profili kümesi içerisindeki dağılımı	34
Şekil 2.18. Hedefe ait yansıtıcılık değerinin (normalize) hedef tiplerine göre dağılımı.....	35
Şekil 2.19. Özniteliklerin etki analizi sonucu ağırlıklandırılması	35
Şekil 2.20. Lambda-Loss grafiği	36
Şekil 2.21. CNN ağ bileşenlerinin temsili	41
Şekil 2.22. YOLO ızgara yapısı	43
Şekil 2.23. Etiketlenen verilerin ızgara hücrelerine atanması	44
Şekil 2.24. YOLO tahmin yöntemi tanımı.....	45
Şekil 2.25. SOA fonksiyonel bileşenleri	49
Şekil 2.26. Web servisi kullanımı.....	49
Şekil 2.27. Merkezi hedef sınıflandırma kütüphanesi mimarisi.....	51
Şekil 3.1. Ardışıl menzil profillerinin temsili gösterimi.....	54
Şekil 3.2. Geçiş matrisi örneği ve durum geçiş diyagramı.....	55
Şekil 3.3. Ardışıl menzil profili sınıflandırma adımları akış diyagramı	56
Şekil 3.4. Ardışıl menzil profili sınıflandırma adımları sözde kod gösterimi	57

Şekil 3.5.	Özgün füzyon (AMPF) yöntemi akış diyagramı.....	58
Şekil 3.6.	Özgün füzyon (AMPF) yöntemi sözde kod gösterimi	59
Şekil 4.1	Sentetik olarak menzil profili elde edilen hedeflere ait 3 boyutlu tasarım dosyaları	62
Şekil 4.2.	Sentetik verinin eğitim, geçiş matrisi ve test gruplarına tasnifi	63
Şekil 4.3.	Kuru yük taşıyıcı hedef tipine ait menzil profilleri.....	63
Şekil 4.4.	Kargo hedef tipine ait menzil profilleri.....	64
Şekil 4.5.	Yat hedef tipine ait menzil profilleri.....	64
Şekil 4.6.	Balıkçı hedef tipine ait menzil profilleri	65
Şekil 4.7.	Military Type-1 hedef tipine ait menzil profilleri	65
Şekil 4.8.	Military Type-2 hedef tipine ait menzil profilleri	66
Şekil 4.9.	Military Type-3 hedef tipine ait menzil profilleri	66
Şekil 4.10.	Ölçümsel olarak elde edilen verilerin dağılımı	68
Şekil 4.11.	Ölçümsel olarak elde edilen balıkçı hedef tipine ait menzil profilleri.....	70
Şekil 4.12.	Ölçümsel olarak elde edilen kargo hedef tipine ait menzil profilleri.....	70
Şekil 4.13.	Ölçümsel olarak elde edilen Military Type-4 hedef tipine ait menzil profilleri.....	71
Şekil 4.14.	Ölçümsel olarak elde edilen Military Type-5 hedef tipine ait menzil profilleri.....	71
Şekil 4.15.	Ölçümsel olarak elde edilen Military Type-6 hedef tipine ait menzil profilleri.....	72
Şekil 5.1.	Sentetik veri ve PNN algoritması kullanılarak elde edilen menzil profili sınıflandırma sonuçları.....	76
Şekil 5.2.	Sentetik veri ve PNN algoritması kullanılarak precision, recall, f1 sonuçları	77
Şekil 5.3.	Sentetik veri, PNN algoritması ve füzyon algoritması kullanılarak elde edilen menzil profili sınıflandırma sonuçları.....	77
Şekil 5.4.	Sentetik veri, PNN algoritması ve füzyon algoritması kullanılarak elde edilen precision, recall, f1 sonuçları.....	78
Şekil 5.5.	Sentetik veri, PNN algoritması ve MVR metodu ile birlikte kullanılarak elde edilen menzil profili sınıflandırma sonuçları	79
Şekil 5.6.	Sentetik veri, PNN algoritması ve MVR metodu ile birlikte elde edilen precision, recall, f1 sonuçları	79
Şekil 5.7.	Ölçüme dayalı veri ve CNN kullanılarak elde edilen menzil profili sınıflandırma sonuçları.....	81
Şekil 5.8.	Ölçüme dayalı veri, CNN ve füzyon algoritması kullanılarak elde edilen karmaşa matrisi.....	82
Şekil 5.9.	Ölçüme dayalı veri, CNN ve MVR algoritması kullanılarak elde edilen karmaşa matrisi.....	83
Şekil 5.10.	Ölçüme dayalı veri, CNN ve BKS algoritması kullanılarak elde edilen karmaşa matrisi.....	83
Şekil 5.11.	Ölçümsel veri ve CNN sınıflandırıcı ile elde edilen precision, recall, f1 grafikleri.....	84
Şekil 5.12.	Ölçümsel veri ve PNN sınıflandırıcı kullanılarak elde edilen menzil profili sınıflandırma sonuçları.....	85
Şekil 5.13.	Ölçüme dayalı veri, PNN ve füzyon algoritması kullanılarak elde edilen karmaşa matrisi.....	86

Şekil 5.14. Ölçüme dayalı veri, PNN ve MVR algoritması kullanılarak elde edilen karmaşa matrisi.....	87
Şekil 5.15. Ölçüme dayalı veri, PNN ve BKS algoritması kullanılarak elde edilen karmaşa matrisi.....	88
Şekil 5.16. Ölçümsel veri ve PNN sınıflandırıcı ile elde edilen precision, recall, f1 grafikleri.....	88
Şekil 5.17. Ölçüme dayalı veri ve YOLO 1.5 algoritması kullanılarak elde edilen karmaşa matrisi.....	89
Şekil 5.18. Ölçüme dayalı veri, YOLO 1.5 ve füzyon algoritması kullanılarak elde edilen karmaşa matrisi.....	91
Şekil 5.19. Hedefe ait uzunluk değerinin (normalize) menzil profili kümesi içerisindeki dağılımı.....	91



TABLULAR DİZİNİ

Tablo 2.1. Sınıflandırma algoritmalarının çalışma performansı verileri	37
Tablo 2.2. PNN sınıflandırma algoritması için kullanılan parametreler	40
Tablo 2.3. CNN sınıflandırma algoritması için kullanılan parametre kümesi.....	42
Tablo 2.4. YOLO kapsamında kullanılan parametrelerin değerleri	45
Tablo 4.1. Elde edilen menzil profillerinin sınıflara göre dağılımı	68
Tablo 5.1. Sentetik veri ve PNN algoritması ile elde edilen geçiş matrisi	76
Tablo 5.2. Ölçüme dayalı veri ve CNN algoritması ile elde edilen geçiş matrisi.....	81
Tablo 5.3. Ölçüme dayalı veri ve PNN algoritması ile elde edilen geçiş matrisi.....	85
Tablo 5.4. Ölçüme dayalı veri ve YOLO 1.5 algoritması ile elde edilen geçiş matrisi	90
Tablo 6.1. PNN sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı	94
Tablo 6.2. CNN sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı	95
Tablo 6.3. YOLO sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı	96

SİMGELER VE KISALTMALAR DİZİNİ

\hat{x}_i	: Normalize öznitelik değeri
x_i	: Öznitelik değeri
\bar{x}	: Öznitelik değer ortalaması
σ	: Standart sapma
r	: Kullanıcı tanımlı sıkıştırma parametresi
N_i	: Test pikseline komşu herhangi bir pikselin komşuluk vektörü
w_{ij}	: i ve j pikselleri arasındaki uzaklık
h	: Filtre derecesi
u_j	: Pencere içerisindeki komşu piksel
R_{res}	: Menzil çözünürlük değeri
α	: Radar-hedef bakış açısı
M	: Menzil indisi sayısı
L	: Hedefe ait boy bilgisi
$RP(n)$: Anlamlı menzil profili verisi
S	: Simetri özniteliği
CM	: Kütle merkezi özniteliği
m	: Giriş vektörünün boyutu
σ	: yumuşatma parametresi
N	: Eğitim verisi vektörü sayısı
C_i	: Sınıf bilgisi
P	: Sınıfa ilişkin önsel olasılık değeri
P_k	: k sınıfının seçilme olasılığı
F_k	: k sınıfının sınıflandırma sonuçları içerisinde gözlemlenme frekansı
T_{ij}	: i 'nci durumdan j 'nci duruma geçiş olasılığı

Kısaltmalar

AMPF	: Ardışıl Menzil Profili Füzyon Yöntemi
ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
API	: Application Programming Interface
BDT	: Bilgisayar Destekli Tasarım
BKS	: Behavior Knowledge Space
CAD	: Computer Aided Design
CFAR	: Constant False Alarm Rate
CM	: Confidence Metric
CNN	: Convolutional Neural Network
DL	: Deep Learning
FCNCA	: Feature Selection Neighborhood Component Analysis
FFT	: Fast Fourier Transform
FLIR	: Forward Looking Infra-Red
FMDMT	: Fourier Modified Direct Mellin Transform

FO	: Fiziksel Optik
FoM	: Figure of Merit
GHz	: Gigahertz
HH	: Horizontally Transmitted Horizontally Received
HMM	: Hidden Markov Model
HRRP	: High Resolution Range Profile
HTTP	: Hypertext Transfer Protocol
IP	: Internet Protocol
ISAR	: Inverse Synthetic Aperture Radar
k-NN	: k-Nearest Neighbour
LVQ	: Learning Vector Quantization
MDM	: Membership Degree Matrix
MLP	: Multi-Layer Perceptron
MNIST	: Modified National Institute of Standards and Technology
MNNFC	: Modified Nearest Neighbor Fuzzy Classification
MSTAR	: Moving and Stationary Target Acquisition and Recognition
MVR	: Majority Voting Rule
NLM	: Non-Local Means
NN	: Nearest Neighbour
NATO	: North Atlantic Treaty Organization
NURC	: NATO Undersea Research Center
PCA	: Principal Component Analysis
PET	: Point Enhancement Technique
PNN	: Probability Neural Network
PSM	: Position Specific Matrix
RASES	: Radar Kesit Alanı Kestirimi Yazılımı
RCS	: Radar Cross Section
RKA	: Radar Kesit Alanı
RP	: Range Profile
SAR	: Synthetic Aperture Radar
SBR	: Shooting and Bouncing Rays
SCR	: Signal to Clutter Ratio
SNR	: Signal to Noise Ratio
SOA	: Service Oriented Architecture
SVM	: Support Vector Machine
SVD	: Singular Value Decomposition
TYAR	: Ters Yapay Açıklıklı Radar
URL	: Uniform Resource Locator
VV	: Vertically Transmitted Vertically Received
YSA	: Yapay Sinir Ağları
WWW	: World Wide Web
3DCAD	: 3 Dimension Computer Aided Design

DENİZ HEDEFLERİNİN OTOMATİK OLARAK SINIFLANDIRILMASINDA SOA YAKLAŞIMININ KULLANIMI

ÖZET

Radar verileri kullanılarak deniz hedeflerinin sınıflandırılması modern akademik çalışmalarda önemli bir çalışma alanı olarak ortaya çıkmaktadır. Ancak, hedef tiplerinin birbirine benzer fiziksel özelliklere sahip olmaları ve çalışma uzayı ile ilgili teknik özellikler sebebiyle deniz hedefi sınıflandırma, çözülmesi zor problemlerden biridir. Deniz hedefi sınıflandırma çalışmalarının bir çoğunda anlık ve tekil menzil profili verisi yada sentetik açıklıklı radar verisi kullanılmıştır. Ayrıca radar verileri kullanılarak hedef sınıflandırılması ve kimliklendirilmesi özellikle savunma sistemleri açısından hayati önem taşımaktadır.

Tekil veri kullanarak gerçekleştirilen sınıflandırma çalışmaları dikkate değer bir başarıya ulaşmasına rağmen, bu tez çalışması kapsamında karaya konuşlu x-band radarlardan elde edilen ardışıl menzil profilleri kullanılarak sınıflandırma başarımları artırılmaya çalışılmıştır. Bu çalışma kapsamında hem sentetik olarak elde edilen menzil profilleri hem de saha ölçümleri ile elde edilen ölçüm verileri kullanılmıştır. Sentetik veri üretiminde yedi farklı hedef tipinin bilgisayar destekli tasarım dosyaları ve elektromanyetik saçılma hesabı yapan benzetim yazılımı kullanılarak menzil profilleri üretilmiştir. Hedeflere ait üç boyutlu bilgisayar destekli tasarım dosyaları kullanılarak menzil profili üretimi benzetim ortamında gerçekleştirilmiştir. Ölçümsel veriler için beş farklı x-band radar kullanılarak veri toplanmıştır. Ölçümsel veriler, beş farklı hedef tipine ait 177 farklı hedefin takibi ile toplamda 2387 adet menzil profilinin ardışıl olarak kaydedilmesi ile elde edilmiştir. Menzil profillerinin ardışıl olarak elde edilen alt kümeleri geçiş matrisi olasılıklarının oluşturulması için kullanılmıştır.

Bu tezin amacı, geliştirilen özgün füzyon algoritması (AMPFusion) sayesinde hedeflere ait ardışıl menzil profillerini hesaba katarak daha başarılı sınıflandırma sonuçları elde edilmesini sağlamaktır. Geliştirilen yöntemin başarımını ölçmek adına, olasılıksal sinir ağları (Probabilistic Neural Network (PNN)), katlamalı sinir ağları (Convolutional Neural Network (CNN)) ve YOLO (You Only Look Once) sınıflandırma algoritmaları kullanılmıştır. Ayrıca, literatürde yer alan füzyon algoritmalarından çoğunluk oylama kuralı (Majority Voting Rule (MVR)) ve davranışsal bilgi uzayı (Behavioral Knowledge Space (BKS)) yöntemleri sonuçları ile tez kapsamında geliştirilen ardışıl menzil profili füzyon (AMPF) yöntemi çıktıları karşılaştırılmıştır. Elde edilen sonuçlar göz önüne alındığında tez kapsamında geliştirilen füzyon yönteminin önemli bir sınıflandırma başarımları artışı sağladığı gözlemlenmiştir.

Tez kapsamında sağlanan bir diğer katkı da, Servis odaklı mimari (Service Oriented Architecture (SOA)) kullanılarak merkezi sınıflandırma kütüphanesi geliştirilmesi için kavramsal tasarım çalışması gerçekleştirilmesi olmuştur. Ortaya koyulan

kavramsal tasarım ile SOA servislerini kullanan uzak istemcilerin sınıflandırma hizmeti aldıkları bir yapı önerilmiştir.

Anahtar kelimeler: Ardıřıl Menzil Profili Sınıflandırma, Deniz Hedefi Sınıflandırma, Otomatik Hedef Sınıflandırma, Ölçümsel Menzil Profili, Sentetik Menzil Profili.



MARINE TARGET CLASSIFICATION USING SOA ARCHITECTURE

ABSTRACT

Classification of marine targets using radar data products has become an important area for modern research society. However, due to several reasons such as the similarity between ship structures and spatial specifications, classification of marine targets constitutes a challenging problem. In almost all of the studies, this problem has been handled by focusing on a single instance of range profiles or synthetic aperture radar data. On the other hand, target classification and identification using radar data is vital for defence systems.

However, this approach is seen to achieve only a particular success. This study introduces a novel classification approach that is shown to provide additional classification enhancements by exploiting the extra information extracted from sequential range profiles generated by ground-based x-band radars. With this purpose, both synthetic and measuremental range profiles are taken into consideration. Synthetic profile data are generated for seven marine targets by using an electromagnetic scattering simulation tool. Three dimension computer aided design files used to synthetically generate range profile data. On the other hand, a total of 2387 range profile data of 171 different target tracks are collected for five different marine target class types by using an X-band radar. Each target tracked for a long period of time to gather sequential HRRP data subsets. HRRP data subsets are used to generate HMM based transition matrix probabilities and sequential classification results by evaluating proposed method.

Probabilistic Neural Network (PNN), Convolutional Neural Network (CNN) and You Only Look Once (YOLO) classification algorithms applied to gather classification results. The proposed method results are compared with both single value classification, Majority Voting Rule (MVR) and Behavior Knowledge Space method results. According to the examination results, the proposed classification fusion approach provides remarkable enhancements in the correct classification rates.

By using Service Oriented Architecture (SOA), centralized classification library conceptual model design generated. According to conceptual model design, an architecture is proposed which serves as SOA services to requesting clients.

Key words: Sequential Range Profile Classification, Marine Target Classification, Automatic Target Classification, Measuremental Range Profile, Synthetic Range Profile

GİRİŞ

Radar sistemleri ile deniz hedeflerinin teşhisi ve sınıflandırılması, uzun yıllardan beri yoğun arařtırmaların yapıldığı bir konu olarak önemini korumaktadır. Hedeflere yönelik tespitlerin yeterli olamadığı durumlarda, teşhis ve sınıflandırma işlemleri özellikle savunma sistemleri açısından hayati önem kazanmaktadır.

Radar sistemleri ile deniz bölgelerinde yapılan keşif, tarama ve tanıma faaliyetleri özellikle sınır kontrolü, güvenli ticaret, dost düşman tanıma ve arama-kurtarma gibi faaliyetler açısından büyük önem arz etmektedir. Gerek radar sistemlerine gerekse algoritmik anlamdaki teknolojik gelişmelere bağılı olarak deniz hedefi sınıflandırma gibi zor bir problemin çözümüne yönelik çeşitli yaklaşımlar açık kaynaklarda önerilmektedir. Mevcut öneriler ve sonuçları incelendiğinde, söz konusu problemin henüz tatmin edici düzeyde bir çözüme kavuşturulamadığı görülmektedir. Farklı gemi sınıflarında yer alan gemilerin farklı yapısal tasarımlar nedeniyle oldukça fazla çeşitlilik arz etmesi, farklı hava durumlarına bağılı olarak oluşan deęişken ve yüksek seviyeli deniz kargaşası ile deniz hedeflerinin yansıtıcılık seviyelerinin radar bakış açısına oldukça duyarlı olması tanıma ve sınıflandırma probleminin zorlaşmasında etkili olmaktadır. Bu doğrultuda çözüme kısmen veya tam olarak ulaşabilmek adına, çeşitli deniz hedefi sınıflandırıcı yapıları önerilmektedir.

Deniz hedefi sınıflandırma konusunda yapılan literatür arařtırması sonuçları, hedef sınıflandırma algoritmaları ve fonksiyonel bileşenleri, gerçek radar verilerinin envanteri, ölçümsel verilerin sınıflandırma test sonuçları, bahse konu verilerin sınıflandırılmasında ardışıl verilerin kullanılmasının önemi ve ardışıl verilerin sınıflandırılmasında önerilen özgün füzyon yöntemi incelenmiştir. Önerilen özgün füzyon yöntemine Ardışıl Menzil Profili Füzyon Yöntemi isminin kısaltmasından yola çıkarak AMPF ismi verilmiştir. Ayrıca Servis Odaklı Mimari (Service Oriented Architecture (SOA)) kullanılarak farklı fiziksel lokasyonlardaki sistemlerinin ortak eğitim kütüphanesi ile sınıflandırma işlevini gerçekleştirmesi koşulları irdelenerek kavramsal tasarım ortaya koyulmuştur. Deniz hedeflerinin sınıflandırılması

kapsamında yapılan literatür araştırması, son 35 yıl içerisinde konu ile ilgili çok sayıda bilimsel çalışmanın hazırlandığını gözler önüne sermektedir. Araştırma sonuçları incelendiğinde, çalışmaların, kullanılan veri kaynağı, çıkartılan öznitelikler ve sınıflandırıcı yapıları anlamında birbirlerinden farklılık gösterdiği görülmektedir. Dikkate alınan verinin kaynağı düşünüldüğünde, menzil profilleri başta olmak üzere, SAR/ISAR (Synthetic Aperture Radar / Inverse Synthetic Aperture Radar) görüntülerinin, kızıl ötesi sensör görüntülerinin (Forward Looking Infra-Red, FLIR), sonar görüntülerinin, optik kamera görüntülerinin, veya genel gemi özelliklerinin deniz hedefi sınıflandırmasında kullanıldığı görülmektedir. Farklı veri kaynakları kullanılarak elde edilen öznitelikler, yine çeşitlilik gösteren sınıflandırıcı yapıları ile birlikte kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Öznitelik çıkartma işlemi için büyük önem taşıyan “boy kestirimi” işlemine yönelik araştırmalar da literatürde yer almaktadır.

Sınıflandırma problemlerinde, problemin doğasına uygun özniteliklerin belirlenmesi büyük önem arz etmektedir. Seçilen özniteliklerin farklı sınıflandırma senaryolarına karşı duyarlı olmaması ve gürbüz olması istenilen bir durumdur. Deniz hedeflerinin sınıflandırılmasına yönelik olarak literatürde önerilen öznitelikler incelendiğinde, boy gibi temel bilgilerden birtakım doğrusal dönüşüm katsayılarına kadar çok çeşitli bilgilerin ayrı ayrı veya beraber olarak kullanıldığı görülmektedir. Bunun yanı sıra, tek tek veya birden fazla sınıflandırıcının kombinasyonu biçimindeki sınıflandırıcı yapıları kullanılarak hedef sınıflandırma problemine çözüm sağlanmaya çalışılmıştır.

Araştırılan dokümanların hedef sınıflandırma algoritmalarının çeşitliliğine vurgusu önem arz etmektedir. Bir çok hedef sınıflandırma algoritması literatürde uzun yıllardır kullanılmaktadır. Literatürdeki hedef sınıflandırma çalışmalarının veri kaynağı ISAR görüntüsü, kızılötesi görüntü, menzil profili, optik kamera görüntüsü gibi birçok kaynaktan elde edilebilmektedir. Elde edilen veriye uygulanacak sınıflandırma algoritması da oldukça çeşitli sayıda bulunmaktadır. Her sınıflandırma algoritması için öznitelik seçimi ve uygulanması farklı bir konu olmakla birlikte uygulanan öznitelik seçiminin ardından güven metriği belirleme ihtiyacı oluşmaktadır. Hedef sınıflandırma çalışmalarına girdi olabilecek algoritmalar ile hedeflere ait menzil profillerinin tasniflenmesi, profillerde oluşabilecek anomalilerin giderilmesi, elde edilen profillerin sınıflandırmaya uyumlu hale getirilmesi için

kargaşa giderme yöntemlerinin incelenmesi, hali hazırda literatürde yer etmiş ve kullanılmakta olan ve kullanmak istediğimiz veri ile uyumlu olan öznelik çıkarma yöntemleri ve son olarak da hedef sınıflandırma algoritmalarının elde edilen veriler ile uyumluluğu irdelenmektedir.

Bu tez çalışmasında irdelenen konulardan bir diğeri ise sınıflandırma kütüphanesinin kullanılan veri kümesi üzerindeki başarımını arttırmak için nasıl özelleştirilebileceğidir. Ardışıl verilerin fayda sağlayacağı öngörüsüyle radar sistemlerinde tespit edilen fırsat hedeflerine ait ardışıl menzil profili verileri elde edilmeye çalışılmıştır. Sahada bulunan sistem etrafında seyir halinde olan deniz hedeflerine ait menzil profilleri alınarak ihtiyaç duyulduğunda kullanılmak üzere tasniflenmiştir. Ayrıca, sahadan elde edilen fırsat ölçümlerine ek olarak ardışıl menzil profillerinin benzetim ortamından elde edilme olanakları incelenmek üzere benzetim ortamı hazırlanmıştır.

Yapılan literatür araştırmaları ve karaya konuşlu radar sistemlerinden alınan çıktı kullanılarak uygulanan ardışıl veri sınıflandırma çalışmalarının dikkate değer bir katkı sağladığı sonucuna ulaşılmıştır. Literatür araştırmalarının uygulandığı alanlarda, ilgili hedefe ait ardışıl menzil profillerinin elde edilmesinin sınıflandırma sonuçlarında kümülatif bir başarımlar etkisi yaratacağı gözlemlenmiştir. İrdelenen çalışmaların odaklandığı konular, kullandığı algoritmalar ve elde edilen sonuçlar araştırılmıştır.

Bu tez kapsamında önerilen AMPF özgün füzyon yönteminin literatürde “*late fusion*” olarak adlandırılan son işlem algoritmaları ile kıyaslanması sağlanmıştır. Bahse konu son işlem algoritmaları sınıflandırma sonuçlarının iyileştirilmesi amacıyla sınıflandırma sonuçlarını düzeltmek amacı uygulanmaktadır. Bu tez çalışması kapsamında geliştirilen AMPF yöntemi literatürde sıkça karşılaşılan Majority Voting Rule (MVR) metodu [1] ve Behavior Knowledge Space (BKS) [2] yöntemleri ile karşılaştırılmıştır. MVR metodu son etiket değerini belirlerken olasılık değerleri ve ardışıl veri içerisinde her bir etiketin karşılaşımla olasılıklarını kullanır. BKS yöntemi ardışıl veri içerisindeki belirlenen tekil etiket değerlerinin sayısının kullanıcı tanımlı bir değere eşit ve/veya fazla olması durumunu kontrol eder. Koşul sağlanması durumunda sık karşılaşılan hedef tipine atama gerçekleştirilir. Aksi

durumda ardışıl veri grubu, eğitim esnasında kullanılan verilerde en çok karşılaşılan hedef tipine atanmaktadır. İhtiyaç duyulan karşılaştırma sonuçlarına erişebilmek için MATLAB ve Python ortamlarında sınıflandırma kütüphanesi gerçekleştirilmiştir.



1. HEDEF SINIFLANDIRMA İLE İLGİLİ TEMEL KAVRAMLAR

Deniz hedeflerinin sınıflandırılması kapsamında yapılan literatür araştırması, son 35 yıl içerisinde konu ile ilgili çok sayıda bilimsel çalışmanın hazırlandığını gözler önüne sermektedir. Araştırma sonuçları incelendiğinde, çalışmaların, kullanılan veri kaynağı, çıkartılan öznitelikler ve sınıflandırıcı yapıları anlamında birbirlerinden farklılık gösterdiği görülmektedir. Dikkate alınan verinin kaynağı düşünüldüğünde, menzil profilleri [3] - [23] başta olmak üzere, SAR/ISAR (Synthetic Aperture Radar / Inverse Synthetic Aperture Radar) görüntülerinin [24] - [34], kızıl ötesi sensör görüntülerinin (Forward Looking Infra-Red, FLIR) [35], sonar görüntülerinin [36], optik kamera görüntülerinin [37], [38] veya genel gemi özelliklerinin [39] deniz hedefi sınıflandırmasında kullanıldığı görülmektedir. Farklı veri kaynakları kullanılarak elde edilen öznitelikler, yine çeşitlilik gösteren sınıflandırıcı yapıları ile birlikte kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Öznitelik çıkartma işlemi için büyük önem taşıyan “boy kestirimi” işlemine yönelik araştırmalar da literatürde yer almaktadır [40].

Sınıflandırma problemlerinde, problemin doğasına uygun özniteliklerin belirlenmesi büyük önem arz etmektedir. Seçilen özniteliklerin farklı sınıflandırma senaryolarına karşı duyarlı olmaması ve gürbüz olması istenilen bir durumdur. Deniz hedeflerinin sınıflandırılmasına yönelik olarak literatürde önerilen öznitelikler incelendiğinde, boy gibi temel bilgilerden birtakım doğrusal dönüşüm katsayılarına kadar çok çeşitli bilgilerin ayrı ayrı veya beraber olarak kullanıldığı görülmektedir. Bunun yanı sıra, tek tek veya birden fazla sınıflandırıcının kombinasyonu biçimindeki sınıflandırıcı yapıları kullanılarak hedef sınıflandırma problemine çözüm sağlanmaya çalışılmıştır.

1992 yılında Zhongliang çalışmasında, ötelemeye, ölçeklendirmeye ve dönme açısına bağlı değişimleri kompanze eden “moment değişmezlerinin” gemi sınıflandırma alanındaki uygulaması anlatılmıştır[35]. İki boyutlu verilerden elde edilecek ve Hu'nun tanımlamış olduğu yedi adet moment değişmezinin öznitelik olarak kullanılabilmesi değerlendirilmiştir. Elde edilen moment değişmezlerinin

lineer diskriminant analizi (Linear Discriminant Analysis (LDA)) ve en yakın komşuluk sınıflandırıcı yapılarına girdi olarak sağlanması ile gemi sınıflandırma analizlerinin yapıldığı görülmektedir.

Inggs ve çalışma arkadaşlarının hazırladığı ve Fourier Modified Direct Mellin Transform (FMDMT) dönüşümünün gemi sınıflandırmada kullanıldığı araştırmalar [12] ve [14] çalışmalarında verilmektedir. Çalışmalarda öncelikli olarak sınıflandırma amaçlı kullanılan menzil profillerinin girişim, bakış açısı ve genlik salınımlarına bağlı olarak değişkenlik gösterdiği, bunun da sınıflandırmayı olumsuz etkilediği belirtilmiştir. Menzil profillerindeki ölçek salınımlarını kompanze eden Mellin ve zaman kaymasını kompanze eden Fourier dönüşümlerinin birleşimi olan FMDMT dönüşümü katsayıları öznitelik olarak kullanılmıştır. Mellin dönüşümünün Fourier dönüşümü sonrası elde edilen verinin sadece pozitif frekanslara karşılık gelen yarısına uygulanması gerektiği belirtilmiştir. Sınıflandırıcı olarak ise Kohonen's Learning Vector Quantization (LVQ) sinir ağı dikkate alınmıştır. Sınıflandırma testlerinde genel olarak $[0^{\circ}-30^{\circ}]$ derece yatay bakış açısı aralığında sınıflandırma başarımının en yüksek olduğu görülmüştür. Bununla birlikte, performans düşük olsa da yarıya kadar 90° yatay bakış açılarına kadar sınıflandırmanın mümkün olabileceği değerlendirilmektedir. Lockheed Martin Canada tarafından uygulanan hiyerarşik gemi sınıflandırma analizleri çalışmasında sınıflandırma amacıyla ilk olarak ISAR veya SAR görüntüsünde gürültünün ortalama ve varyans değerleri kullanılarak sadece hedefin bulunduğu bölge elde edilmektedir [28]. Bu işlemin ardından, elde edilen görüntüde en yüksek yansıtıcılığa sahip %10'luk kısımların dağılımı incelenerek, söz konusu geminin askeri veya sivil olduğu şeklindeki ön sınıflandırma değerlendirmesi yapılmaktadır. Bu noktada, askeri gemilerin saçıcı merkezlerinin ortada, sivil gemilere ait saçıcıların ise merkez dışında konumlandığı bilgisinden yararlanılmaktadır. Ön sınıflandırma sonucunda gemilere "Line (Askeri)", "Merchant" veya "Unknown" etiketleri atanmaktadır. 80 m ve altındaki uzunluğa sahip gemiler ise dikkate alınmamaktadır. Askeri olarak önsel etiketlenen gemi verilerine boya bağlı olasılık yoğunluk fonksiyonları uygulanmakta ve böylelikle ilgili gemi hedefinin hangi askeri sınıfa ait olduğu belirlenmektedir. Bu aşamada, her bir askeri gemi için boya bağlı olasılık yoğunluk fonksiyonu türetilmektedir. Sivil gemiler için ise, veriden elde edilen dalgacık (wavelet)

katsayıları yapay sinir ağı algoritmasına sokularak sivil gemi tipi belirlenmektedir. Hedeflere ait bilgisayar destekli tasarım (Computer Aided Design (CAD)) modelleri ve hesaplama araçları kullanılarak elde edilen veriler ile yapılan testlerde sivil gemilerin yaklaşık %50 oranında askeri olarak sınıflandırıldığı görülmüştür.

Qinetiq tarafından hazırlanan bir çalışmada, sınıflandırma performansını artırmak için Bayes sınıflandırıcı yapısına yapılan eklemeler ve elde edilen sonuçlar sergilenmektedir [13]. 3 m uzamsal çözünürlüğe sahip bir kara konuşlu radar sisteminden elde edilen veri setleri kullanılmıştır. Sınıflandırıcı yapısı olarak Bayes teoreminden yararlanılmıştır. Sınıflandırıcı performansını artırmak üzere üç farklı eklemede bulunulmuştur. Birinci yaklaşım minimum benzerlik (Minimum Likelihood) yaklaşımıdır. Bu kapsamda, sınıflandırma aşamasında belirli bir eşik değerden daha küçük olasılık sunan değerler değerlendirme dışına atılmaktadır. Tipik değerler olarak 0.1 ve 0.000001 değerleri kullanılmıştır. İkinci ekleme olarak kullanılan belirsizlik önleme (Ambiguity Reject) prensibine göre, birbirine yakın olasılıksal değerler oluşması durumunda test verisi tanımsız (Unknown Class) sınıfına dahil edilmektedir. Bu doğrultuda, benzetimlerde en yüksek iki olasılık değerinin birbirine oranının 1.25'ten küçük olması durumunda test verisi bilinmeyen sınıfa atanmıştır. Üçüncü yaklaşım ise sınıflandırıcı sonuçları füzyonu (Classifier Results Combination) yaklaşımıdır. Tek veri yerine birden fazla profilin sonuçlarının dikkate alındığı durumu ifade etmektedir. Sınıflandırıcı yapısında dikkate alınan bir diğer durum ise farklı bakış açıları için farklı sınıflandırıcılar tanımlanmış olmasıdır. Benzetimlerde altı farklı öznitelik kullanılmıştır: Belirli bir eşiğin üzerinde kalan tepe sayısı, profil genlik ortalamasının üstünde kalan kısmın yüzde olarak değeri, normalizasyon sonrası maksimum değer, maksimum değer konumu, standart sapma ve boy. Özniteliklerden her defasında sadece biri dışarda bırakılarak en az ve en fazla etkili öznitelik araştırması da yapılmıştır. Sonuçta, tepe sayısının en az, maksimum değer konumunun ise en fazla katkıda bulunduğu görülmüştür. Ayrıca toplamsal sınıflandırma performansına bakıldığında ekleme yaklaşımlarının üçünün de dikkate alınması durumunda en yüksek sınıflandırma performansına ulaşıldığı görülmüştür.

Position Specific Matrix (PSM) sınıflandırıcı yapısının kullanıldığı bir başka çalışmada, nokta iyileştirme tekniğinin (point enhancement technique, PET) gemi

hedefi sınıflandırma problemine olan uygulaması anlatılmıştır [14]. İlgili teknik ile geleneksel FFT (Fast Fourier Transform) yöntemi ile elde edilene göre daha yüksek çözünürlüklü menzil profilleri elde edilebilmektedir. Profillerin kendisi (genlik dağılımı), boy bilgisi ve kalibrasyon hedefi varlığında elde edilmiş Radar Kesit Alanı (RKA) değerleri ayrı birer öznitelik olarak kullanılmıştır. Sınıflandırıcı yapısı olarak ise iki ayrı yöntem kullanılmaktadır. Birinci yöntem en yakın komşuluk (nearest neighbor, NN) yöntemidir. Bu yönteme göre, tüm sınıflara ait eğitim öznitelik vektörleri ile her bir test öznitelik vektörü arası uzaklık hesaplaması yapılır. En küçük değeri veren eğitim verisinin olduğu sınıfa atama yapılır. Uzaklık anlamında Öklid, Manhattan ve Minkowski uzaklıkları kullanılmıştır. İkinci sınıflandırıcı olarak kullanılan PSM yöntemine göre ise, menzil profilinin konum alanları ve profilin genlik aralığı için kuantalama yapılır. Bu doğrultuda, eldeki eğitim verileri kullanılarak menzil-genlik matrisinde menzillere göre genliklerin görülme sıklıkları belirlenir. Eşit olmayan eğitim verisi durumunda normalizasyon yapılır. Sonuçta, test verisinin her bir menzil aralığına karşılık gelen kuantalanmış genlik değerleri ile sınıfa ait PSM değerleri çarpılarak her bir sınıfın benzerlik skoru oluşturulur. En yüksek skora sahip sınıf seçilir. Gerçek veriler ile yapılan testlerde PET ile elde edilen menzil profilleri ve PSM sınıflandırıcı kullanma durumunda yüksek sınıflandırma başarımı sağlandığı görülmüştür.

Pilcher ve çalışma arkadaşlarının gemi hedefi sınıflandırma kapsamında yapmış oldukları bilimsel incelemeler [15], [16] ve [18] çalışmalarında sergilenmektedir. Pilcher, 6 adet gemi hedefi için yapılan sınıflandırma analizleri sunduğu bir çalışma yapmıştır [12]. Öncelikle ProEngineer aracı kullanılarak üretilen gemi hedefi modellerinden XPATCH aracı kullanılarak menzil profilleri elde edilmiştir. Oluşturulan menzil profillerine [-25,-30] dB seviyelerinde sinyal gürültü oranı (Signal-to-Noise Ratio (SNR)) oluşacak şekilde gürültü eklenmiştir. Yatay-yatay (HH), ve dikey-dikey (VV) polarizasyon durumları için beşer adet öznitelik çıkartımı yapılmıştır. Çıkarılan öznitelikler: Profildeki tepe sayısı, en yüksek genlikli iki tepe arası uzaklık, boy, kütle merkezi ve en yüksek genlikli tepe konumunun yakın hedef ucuna uzaklığı biçimindedir. Boy hesabında çalıştırılan sabit yanlış alarm oranı (Constant False Alarm Rate (CFAR)) algoritması kapsamında yanlış alarm olasılığı değeri 0.0001 olarak kullanılmıştır. Sınıflandırıcı olarak en yakın komşuluk, Bayes

ve çok katmanlı geriye yayılma (Multilayer Perceptron (MLP)) sınıflandırıcıları kullanılmıştır. Sınıflandırıcı çıktılarında, karar aşamasından önce bir sınıflandırmaya uygunluk ölçütü (confidence metric, CM) belirlenmiştir ve bu ölçütün değeri %98 olarak uygulanmıştır. CM ifadesi Biweight çekirdekleri (kernel) kullanılarak elde edilmiştir. Sınıflandırma testleri CM'nin uygulanmadığı ve uygulandığı durumlar için yapılmıştır. NN sınıflandırıcısının en yüksek performansı sağladığı görülmüştür. CM'nin uygulanması durumunda, çok sayıda profilin sınıflandırmaya uygun olmaması sebebiyle sınıflandırma dışında tutulduğu fark edilmiştir. Örnek vermek gerekirse, balıkçı gemileri için sınıflandırılmama oranı %96 seviyelerine çıkmıştır. Bir başka çalışmada ise, sınıflandırma çalışmaları öncesindeki veri hazırlama ve öznitelik çıkartımı işlemleri ilgili çalışmadan farklı olarak sınıflandırıcı yapısında farklı yaklaşımlar dikkate alınmıştır [15]. Şöyle ki; öncelikle en yakın komşuluk, Bayes ve MLP sınıflandırıcıları bireysel olarak uygulanmakla birlikte, bu sınıflandırıcıların kombinasyonları da dikkate alınmıştır. Sınıflandırıcı kombinasyonları oluşturmada da üç farklı yaklaşım izlenmiştir. İlki olan toplama kuralında, üç sınıflandırıcı için oluşturulan diskriminant ifadeleri öncelikle normalize edilmiş ve toplanmıştır. Bu noktada NN ve MLP çıktıları önsel olarak ters alma işlemine tabi tutulmuştur, böylelikle yüksek değerler yüksek uyumluluğa denk gelebilmiştir. Toplama sonucunda en yüksek değere karşılık gelen sınıf seçilmiştir. İkinci ve üçüncü yaklaşımlar ise, sırasıyla “orta değer (median) alma” ve bireysel sınıflandırıcı çıkışlarının tekrar bir yapay sinir ağına uygulanması esaslarına dayanmaktadır. Yapılan testler sonucunda, bireysel anlamda NN'nin, sınıflandırıcı kombinasyonları düşünüldüğünde ise sinir ağı tabanlı sınıflandırıcı kombinasyonunun en yüksek başarıyı sağladığı görülmüştür. Aynı çalışma grubunun hazırlamış olduğu makalede ve bildiri çalışmaları derlenmekte ve yapılan sınıflandırma işlemleri hakkında daha detaylı bilgi verilmektedir [15], [16], [18]. Diğer çalışmalarda olduğu gibi bu çalışmada da sınıflandırıcı olarak NN, Bayes ve MLP sınıflandırıcıları bireysel olarak veya çoklu sınıflandırıcı kombinasyonları biçiminde kullanılmıştır. Sınıflandırıcı çıktılarında karar vermeden önce bir sınıflandırmaya uygunluk ölçütü (CM) belirlenmiştir ve bu metriğin değeri %98 olarak uygulanmıştır. CM ölçütünün esas görevi, bir test verisinin ancak belirli bir uygunluk seviyesi sunması durumunda sınıflandırmaya tabi tutulması, aksi durumda ise değerlendirmeye alınmamasıdır. Bu ölçüt, örneğin test verisi için tüm sınıflara

ilişkin diskriminant değerleri benzer seviyelerde olması durumunda sınıflandırma işlemine izin vermemektedir. Sınıflandırma testleri, bireysel sınıflandırıcılar, sınıflandırıcı kombinasyonları, CM'nin uygulanmadığı ve uygulandığı durumlar ile birlikte bilinmeyen veriler bulunup bulunmama durumları için yapılmıştır.

2011 yılında Liu ve çalışma arkadaşlarının gemi hedefi sınıflandırma konusunda yaptıkları araştırmalarda, Modified Nearest Neighbor Fuzzy Classification (MNNFC) yöntemi ile yapılan gemi hedefi sınıflandırma çalışması anlatılmaktadır [19], [20]. Çalışmada, menzil profilini en fazla etkileyen unsurların kabin, mast, funnel ve radar anteninin olduğu vurgulanmıştır. Menzil profilinden çıkarılabilecek ve kararlı olduğu ifade edilen öznitelikler ile sınıflandırma işlemleri yapılmıştır. Bu çalışma kapsamında boy bilgisi, dispersant (dağınıklık) katsayısı, simetri katsayısı ve belirli sayıda merkezi momentler öznitelik olarak kullanılmıştır.

Sınıflandırma aşamasında, öncelikle tüm sınıflara ait menzil profillerinden elde edilen özniteliklerin sütunlar halinde yan yana dizilmesi ile $M \times Q$ boyutlu öznitelik matrisi elde edilmektedir. M boyut sayısını, Q ise toplam eğitim verisi sayısını ifade etmektedir. İkinci aşamada, test edilecek veriye ilişkin öznitelik vektöründen eğitim öznitelik matrisi çıkarılarak yine $M \times Q$ boyutlu fark matrisi elde edilmektedir. Öznitelik matrisindeki her bir elemana bulanık mantık fonksiyonu uygulanır ve üyelik derecesi matrisi (membership degree matrix, MDM) elde edilir. Son olarak ise, elde edilen matriste farklı özniteliklere farklı ağırlıklar uygulanarak ve sütun toplama işlemi yapılarak MDM matrisi $1 \times Q$ boyutlu vektöre indirgenir. Bu vektör içinde en yüksek değere sahip verinin ait olduğu sınıfa atama yapılır. Hiyerarşik bir gemi hedefi sınıflandırma uygulaması çalışmasında tanıtılmaktadır [20]. Çalışmada öncelikli olarak sınıflandırma aşamasından önce yapılacak olan sıra dışı menzil profillerinin elenmesi, SNR değerini artırmak için profil entegrasyonu ve profil hizalama gibi işlemlere değinilmiştir. Menzil profillerinden çıkarılan öznitelikler belirtilen öznitelikler ile aynıdır. Sınıflandırma aşamasında öncelikle boy özneliğine göre bazı sınıfların elenmesi sağlanmaktadır. Ardından, sırası ile dağınıklık ve simetri özniteliklerine göre sınıf eleme işlemi gerçekleştirilmektedir. En son aşamada ise, kalan sınıflar için yapay sinir ağı metodu işletilerek sınıflandırma prosedürü tamamlanmaktadır. Schimpf'in yer aldığı çalışma grubunun gemi sınıflandırma özelinde yapmış olduğu bilimsel çalışmaların ilkinde deniz hedefi sınıflandırmada

kullanılabilecek birtakım özniteliğe yönelik analizler sergilenmiştir [17]. İlgili çalışmada, 17 GHz bandında çalışan MARSIG radar sistemi dikkate alınmıştır. Öncelikli olarak, menzil profili üretiminde kullanılan benzetim aracı tanıtılmıştır. Bu benzetim aracında atmosfer, yayılım (TERPEM aracı ile) vb. etkilerin de dikkate alınabildiği görülmektedir. Menzil profillerinin gölgeleme ile birlikte özellikle uzak mesafelere bağlı olarak ortaya çıkan düşük SNR, düşük sinyal kargaşa oranı (Signal to Clutter Ratio (SCR)) ve çoklu hedef durumlarından etkilendiği belirtilmiştir. Gemi sınıflandırmada kullanılabilecek ve RKA bazlı sekiz adet öznitelik sıralanmıştır. İlgili özniteliklerden önemli olanları N adet güçlü saçıcının menzil değerleri, toplam RKA, ortalama RKA değerinin RKA'nın standart sapma değerine oranı ve güçlü saçıcı noktalara ait RKA toplamının toplam RKA'ya oranı biçimindedir. Sıralanan sekiz adet öznitelik, radardan dört farklı mesafe için benzetim ve ölçümler aracılığı ile elde edilmiştir. Elde edilen özniteliklerin farklı mesafelere göre değişme durumu Kolmogorov-Smirnov (KS) testi ile hesaplanmıştır. Test sonucunda mesafeye göre değişiklikler olduğu görülmüştür. Kuzey Atlantik Antlaşması Örgütü (North Atlantic Treaty Organization (NATO)) raporu biçiminde yayınlanan bir çalışmada ise, temel olarak, gemi sınıflandırmada çoklu yansıma ve yayılım etkilerinin analizi yapılmıştır [23]. Diğer birkaç çalışmanın derlemesi biçiminde olan çalışmada öncelikle gemi sınıflandırmada kullanılan veri kaynakları ve bu kaynaklardan birisi olan menzil profillerinin nelerden etkilendiği belirtilmiştir. Bu etkenler gölgeleme, çoklu gemi durumu, düşük SNR, düşük SCR, gemi önü veya arkasındaki sinyal yayılmaları gibi etkenlerdir [17]. Çalışmada menzil profilinden gemi boyunun kestirimine yönelik iki metottan bahsedilmiştir. Daha başarılı olduğu belirtilen ilk metoda göre, kargaşanın ortalama seviyesine ilaveten standart sapmanın belirli bir katsayı ile (10 olarak alınmış) çarpılması sayesinde profil verisindeki anlamlı verinin bulunduğu bölge tespit edilebilmekte ve gemi hedefinin boyu hesaplanabilmektedir. Sınıflandırıcı olarak PSM metodunun akışı sunulmuştur. Bu akışa göre; öncelikle boy kestirimi yapılır, eldeki eğitim profilleri aynı hizaya ayarlanır, genlik seviyeleri (dB olarak kullanılması önerilmiş) kuantal bölgelerine ayrılır, her bir sınıf için referans PSM oluşturulur, test profilleri için yaralılık katsayısı (Figure of Merit, FoM) belirlenir, en yüksek benzerlik derecesi değeri üreten sınıfa atama yapılır. Gemi sınıflandırmada kullanılabilecek geometrik, istatistiksel ve yapısal karakteristikleri sunan 14 adet öznitelik tariflenmiştir. Benzetimlerde ve ölçümlerde

bu özniteliklerin birbirinden bağımsız olanlarının gruplanarak kullanıldığı görülmüştür. Yapılan sınıflandırma analizlerinde mesafeye de bağlı olan çoklu yansıma ve yayılım etkilerinin özniteliklerin performansını önemli ölçüde etkilediği görülmüştür. Dolayısı ile test esnasında tek bir profilden ziyade birden fazla profilin dikkate alınmasının önemli olduğu vurgulanmıştır.


1.1. Ardışıl Menzil Profili Sınıflandırma

Ardışıl verilerin sınıflandırılması literatürde sıkça karşılaşılan bir durumdur. Ardışıl menzil profili sınıflandırma konusunda yapılan literatür araştırmalarında birçok farklı yaklaşımla karşılaşılmıştır. Nilubol, SAR imgelerinin otomatik sınıflandırılması amacıyla bir çalışma kapsamında sınıflandırma algoritması temeli olarak Hidden Markov Model (HMM) kullanılmıştır [41]. Kara hedeflerine ait 1 derecelik aralıklar ile elde edilen SAR görüntüleri kullanılmıştır. Her hedef tipine ait HMM'ler oluşturulmuştur. Verilerin önışlemeye tabi tutulması ile hem eğitim hem test datası kullanılabilir hale getirilmiştir. Viterbi algoritması kullanılarak elde edilen verilere ait öznitelikler durumlar (state) ile eşleştirilmektedir. Elde edilen gözlem verisinin durum cetveli ile maksimum uyum gösterdiği örnek aranarak test sonucu elde edilmektedir. HMM durum (state) sayısının ve seçilen öznitelik sayısının başarıma etkisi incelenmiştir.

Bir başka çalışmada düşük frekanslı aktif sonar sistemlerinin elde ettikleri sualtı verisinin içerisinde parlayan bölgelerin hedef yada farklı bir nesneden kaynaklı olup olmadığı araştırması gerçekleştirilmiştir [42]. Gerçekleştirilen çalışmada Markov Rastgele Alan (Markov Random Field) algoritması kullanılarak hatalı hedef tahminlerinin azaltılmasına çalışılmıştır.

Çoklu bakış açısının sınıflandırmaya dahil edilmesi amacıyla gerçekleştirilen bir başka çalışmada bir hedefe birden fazla bakış açısından yapılan sinyal gönderimi ve elde edilen geri dönüş sinyali kullanılarak aynı hedefin birden fazla ölçümü elde edilmektedir [43]. Elde edilen sinyaller HMM yardımı ile durum geçiş olasılıkları matrisine aktararak olasılıksal olarak durumlar arası geçiş tahminlerinde bulunmaktadır. Bir sınıfa ait öznitelikler için elde edilen değerlerin istatistiksel olarak geçiş matrisinde sergilenmesi ve bir sonraki duruma geçişte bu olasılıkların kullanılması HMM'in temelini oluşturmaktadır. Hedefe ait birden fazla açıdan alınan

eşzamanlı ölçümler Şekil 1.1 şeklinde gözlemlenebileceği gibi bir hedefin öznitelikler bakımından farklı durumlarda olması sağlayabilmektedir. Farklı açılardan alınan ölçümler sayesinde sınıflandırma başarımının arttığı belirtilmektedir.



Şekil 1.1. Çoklu bakış açısına göre hedef gösterimleri

Hedef sınıflandırmada HMM kullanılması sıkça karşılaşılan bir durum olarak göze çarpmaktadır. Dasgupta, hedef ile sensör arasındaki yön bilgisi kullanılarak HMM mimarisi ile hedef-sınıf temelli bir sınıflandırma çalışması gerçekleştirmiştir [44]. Benzetim ortamında hazırlanan akustik verisi ile bir çalışma gerçekleştirilmiştir. HMM tanımlanırken durum yapısı ağaç temelli algoritma ile gerçekleştirilmiştir. Hedeflere ait durum sekansları tariflenerek sınıflandırma başarımı ölçülmüştür. Sınıf temelli HMM'ler sınıfa ait veriler ile eğitilerek her sınıf için ayrı bir HMM oluşturulmaktadır. Test aşamasında hedefe ait sorgulama maksimum benzerlik ile belirlenmektedir.

Hedef sınıflandırma çalışmaları hedefi gözlemleyen noktaların çeşitliliğine göre farklılaşabilmektedir. Bir hedefi birden fazla noktadan gözlemleyebildiğimiz durumlarda HMM üzerinde yapılan değişiklik ile sınıflandırma başarımının arttırılabileceği gözlemlenmiştir [45]. HMM'de bulunan durum geçiş matrislerinin tek bir gözlem noktası için değil de birden fazla gözlem noktası için doldurulması sonucu ortaya çıkan son matrisin kullanılması ile başarımın arttırılabileceği gözlemlenmiştir. İki farklı gözlem noktası ile gerçekleştirilen çalışma en yüksek

başarımı sergilemiştir. iki perspektiften de elde edilen benzerlik (likelihood) değerlerinin toplanması ile füzyon (fusion) değeri elde edilmiş olmaktadır.

Bir farklı çalışmada [46] ise dalgacık (wavelet) öznitelik çıkartımı yöntemi kullanılarak öznitelikler belirlenmiştir. Çıkarılan özniteliklerin 6 farklı sınıfın sınıflandırılmasında kullanılması hedeflenmiştir. Gerçekleştirilen çalışmada HMM kullanılarak hedef sınıflandırma başarımı ölçülmüştür.

Bazı çalışmalarda sınıflandırma sonuçlarına odaklanmak yerine HMM tarafından kullanılacak olan durum geçiş matrisinin üretilmesi üzerine yoğunlaşmıştır. Sualtı hedeflerin tespitine yönelik geliştirilen bir çalışmada sualtı hedeflerine yönelik sınıflandırma çalışmalarında kullanılmak üzere geliştirilen 20 durumluk bir durum geçiş matrisi HMM için üretilmiştir [47].

Hedef sınıflandırma çalışmalarında bir farklı çalışmada yüksek çözünürlüklü sonar imgelerini sınıflandırma için iki tekniğin birleşimi ile gerçekleştirilmiştir [48]. Birinci aşamada temizleme algoritması (Despeckling Algorithm) temelli bir filtre kullanılmaktadır. İkinci aşamada gölgeli ve parlak alanların ayrıldığı filtreleme aşaması gerçekleştirilmektedir. Geometrik öznitelikler bu filtreleme sonucu oluşan alanlardan çıkarılmaktadır. Çıkarılan öznitelikler Markov Chain Monte Carlo yaklaşımı ve karar ağacı (Decision Tree) sınıflandırıcısı kullanılarak sınıflandırmada kullanılmaktadır. 30 farklı öznitelik kullanılarak 5 farklı sınıfın sınıflandırma başarımı çalışılmıştır. Sınıflar silindir, balık, kaya, varil ve traktör tekeri olacak şekilde belirlenmiştir. Markov Chain Monte Carlo yöntemi kullanılarak öznitelikler en önemli olandan en önemsiz doğru sıralanarak indekslenmektedir. NURC (NATO Undersea Research Centre) tarafından hazırlanan SIGMAS isimli benzetim yazılımı ile veriler üretilmiştir.

İrdelenen çalışmaların içerisinde özellikle dikkati çeken [49] çalışması bu tez kapsamında gerçekleştirilmesi planlanan çalışma ile birçok ortak içerik barındırmaktadır. Elde edilen yüksek çözünürlüklü menzil profillerini kullanarak üç farklı kara hedefinin sınıflandırılması üzerinde çalışılmıştır. Elde edilen verilerin ham halinden kullanılabilir şekle dönüştürülmesi için Fourier Transform kullanılmıştır. Elde edilen verilerin boyut azatılımı Principal Component Analysis (PCA) ile gerçekleştirilmiştir. Üç farklı sınıflandırma algoritması sonuçların

inanırlılığını ortaya koymak için gerçekleştirilmiştir. Bayes temelli, KNN temelli ve yapay sinir ağı temelli üç farklı sınıflandırma algoritması gerçekleştirilmiştir. Birden fazla perspektiften alınan aynı hedefe ait profillerin sınıflandırma sonuçlarının bir araya getirilerek kombine bir sonuç üretilmesi temeline dayanmaktadır. Perspektif sayısının artması ile başarımın arttığı gözlemlenmekte ve en büyük başarım sıçraması 2 perspektifli çalışma ile gelmektedir. 5 perspektifli sınıflandırma çalışması en büyük başarımı göstermekte ve perspektif sayısı arttıkça başarı oranı iyileşmektedir. Sınıflara ait 360 dereceyi kapsayan 10500 adet profilden oluşturulan bir veritabanı oluşturulmuştur. Bu veritabanının bir kısmı test bir kısmı eğitim için ayrılmıştır. Elde edilen kontrollü verinin sınıflandırma başarımı test edilmiştir.

Çok noktadan bakış açısını kullanarak hedef sınıflandırma başarımını arttırmaya çalışan literatürdeki çalışmaların çoğu sınıflandırma kararının oluşturulması için çoklu test verisi kullanmaktadır. Yüksek çözünürlüklü menzil profillerinin (High Resolution Range Profile (HRRP)) sınıflandırılması süreci sırasında sınıflandırma algoritması olarak HMM ve öznitelik çıkartımı için RELAX algoritmasının kullanıldığı sıkça rastlanılan bir konudur [50]. Bu çalışmada her bir HRRP için dikey gözlem açısının sabit olduğu kabul edilmiştir. Bazı çalışmalar sıralı hedef ekoları için gözlem açılarının sırasını optimize etme problemi ile ilgilenmiştir [51]. Ardışıl saçılma verileri oluşturmak için kullanılan beş farklı su altı hedefi kullanılmıştır. Tüm hedeflerin eşit miktarda karşılaşıldığı varsayılmıştır. Performans ölçümü HMM sınıflandırma algoritması kullanılarak gerçekleştirilmiştir. Bingnan, çoklu görünüm yaklaşımı sonuçlarına ulaşmak için hava hedeflerine ait simülasyon tabanlı ISAR verilerini 2-5 segmente bölmüştür. Öznitelik çıkarma için RELAX algoritması ve sınıflandırma algoritması olarak HMM kullanılmaktadır. Hedef ait her segmentten yansıyan yankıların farklı hedefler olarak değerlendirildiği bir çalışma olmuştur. Son sınıflandırma kararının verilebilmesi için çok görünümlü sınıflandırma sonuçları birleştirilmektedir. Bir başka çok görünümlü yaklaşım [52], 10 farklı kara taşıtının menzil profillerinin ardışıl olarak elde edilmesi ve otomatik hedef tanıma kullanılarak sınıflandırılmasına dayanmaktadır. Test edilen menzil profili ile o menzil profiline en yakın görüş açısında olan 5 farklı menzil profili arasındaki korelasyon incelenmiştir. Maksimum korelasyon nihai sınıflandırma kararı olarak seçilmiştir. Bir başka çalışmada [53], 8 farklı hedefe ait radar kesit alanı verisi

benzetim yazılımı kullanılarak sentetik olarak hesaplanmıştır. Sentetik olarak oluşturulan ardışık radar kesit alanı veri kütüphanesi ve HMM sınıflandırma altyapısı kullanılarak manevra yapan hedef tanıma çalışması yapılmıştır. [54] numaralı çalışmada, 10 farklı kara taşıtının sınıflandırılması için çok yönlü SAR görüntüsü kullanılmıştır. Her bir hedefe ait aynı dikey bakış açısında ancak farklı yatay bakış açılarında veriler seçilerek çalışma gerçekleştirilmiştir. Çoklu hedef sınıflandırma sonuçlarına erişebilmek için hedeflere ait sınıflandırma sonuçlarının sıralama temelli ve Bayes temelli karar mekanizması kullanılmıştır. Başka bir örnek çalışmada yine radar menzil profilleri kullanılarak çok ölçekli sınıflandırmadan bahsedilmektedir [55]. Üç hava hedefine ait sentetik olarak üretilen menzil profillerinin köşe noktalarının öznitelik olarak kullanıldığı sınıflandırma çalışmasını aktarmaktadır. Sınıf üyelik derecesini tanımlamak için ağırlık algoritması kullanılarak başarı artırılmıştır. HRRP dizisi, tekil değer ayrıştırması (Singular Value Decomposition (SVD)) kullanılarak açı ve mesafe bileşenlerine ayrılmıştır. Mesafe bileşenine ait sınıflandırma ve açı vektörüne ait doğrulama bilgileri birleştirilmiştir. Ayrıca bu çalışmada hem sentetik hem de ölçüm verisi kullanılmıştır. Wang, 10 farklı yer hedefi içeren MSTAR veri tabanında bulunan SAR görüntülerini kullanmıştır. Hareketli ve sabit hedeflere ait sınıflandırma sonuçları geleneksel boyut azaltımı ve destek vektör makineleri (Support Vector Machine (SVM)) kullanılarak irdelenmiştir. Tek dikey açıda ve çoklu yatay açı örnekleme ile önemli sınıflandırma başarımı sağlandığı gözlemlenmiştir. Bir başka çalışmada [56], üç boyutlu uçak modellerinden elde edilen HRRP verileri mikrodalga yankısız oda kullanılarak toplanmıştır. Veritabanındaki her bir HRRP Learning Vector Quantization (LVQ) kullanılarak sınıflandırılmıştır. Ardışıl menzil profili alt kümesine ait her bir tekil sınıflandırma sonucu çoğunluk oylama kuralı (MVR) kullanılarak birleştirilmektedir.

Önceden belirlenmiş dikey ve yatay hedef bakış açılarına yönelik HRRP verisi elde etmek son derece zor olabilir. Dolayısıyla, bu tez kapsamında üretilen algoritmaların başarımını ölçmek için ölçüm tabanlı veriye ek olarak nümerik elektromanyetik bir simülasyon yazılımı olan RASES [57] kullanılarak üretilen sentetik üretilen menzil profili verisi kullanılmıştır. Bu yazılımı kullanarak önceden belirlenmiş özelliklere karşılık gelen HRRP verilerinin oluşturulması mümkün olmaktadır. Bu çalışma kapsamında sınıflandırma başarısını artırmayı amaçlayan yeni bir füzyon yöntemi

önerilmiştir. Geleneksel tek menzil profili bazlı sınıflandırma başarımını arttırmak için ardışıl profillerden yararlanarak sentetik olarak üretilen verileri olasılıksal sinir ağı (Probabilistic Neural Network (PNN)) tabanlı sınıflandırıcı ile eğitim sürecine dahil edilmektedir. Sınıflandırma amacıyla kullanılan verilerden altı farklı öznetelik çıkarılmaktadır. Sıralı olarak, sınıflandırma sonuçları son işlemeye girdi olarak verilmektedir. Sentetik veri ile gerçekleştirilen sınıflandırma sonuçlarındaki başarımların artışı ölçüm tabanlı radar verisi ile test edilmektedir. Bu çalışma, zorlu koşullar altında güçlü sınıflandırma performansı sağlamaktadır;

- Sentetik olarak üretilen ardışıl menzil profili verilerinin önerilen yöntem ile sınıflandırma performansı irdelenmektedir.
- Farklı mevkilerde konuşlandırılmış x-band radar istasyonlarından gerçek hedeflere yönelik ölçüm temelli veri elde edilmesi sağlanmaktadır.
- Literatürde yer alan çoğu çalışmanın aksine farklı mevkilerde konuşlandırılmış radar istasyonları sayesinde menzil profilleri üretildiği farklı yükseklik ve bakış açısı değerine sahip olması sağlanmaktadır.
- Önerilen yöntem performansını incelemek için üç farklı sınıflandırma algoritması kullanılmıştır. Kullanılan algoritmalar; konvolüsyonel sinir ağı (Convolutional Neural Network (CNN)), olasılıksal sinir ağı (Probabilistic Neural Network (PNN)) ve YOLO'dur.
- Geçiş matrisi olasılıklarını ve yeni bir füzyon algoritmasını içeren yöntem geliştirilmektedir.
- Önerilen yöntem hem tekil sınıflandırma sonuçları hem de çoklu hedef sınıflandırma sonuçlarını kullanan MVR ve BKS yöntemi sonuçları ile karşılaştırılmaktadır.

2. HEDEF SINIFLANDIRMA KÜTÜPHANESİ

Herhangi bir hedef sınıflandırma uygulamasında, verilerin önsel işlenerek sınıflandırmaya hazır hale getirilmesi, özniteliklerin çıkartılması, veri boyutunun düşürülmesi ve sınıflandırıcı yapısının tasarlanması gibi adımlar yer almaktadır. Bu bölüm içerisinde de hedef sınıflandırma kütüphanesi bileşenleri ve algoritmaları tanıtılmaktadır.


2.1. Veri Önleme

Hedef sınıflandırma çalışmalarında, sınıflandırma işlemlerine tabi tutulacak verilerin öncelikli olarak bir takım ön işlemlerden geçirilerek kullanıma hazır hale getirilmesi gerekmektedir. Bu maksat doğrultusunda, sıra dışı değerler sergileyen verilerin veri setinden çıkarılması (anomali tespiti ve çıkartımı), veri değerlerinin belirli değerler aralığına transfer edilmesi (normalizasyon), belirli değerlerin üstünde veya altında değer sergileyen verilerin değerlerinin sabit bir değere çekilmesi (eşikleme), gürültü giderme, ara değerlendirme veya kargaşa bastırma gibi çok sayıda yöntemden uygulamaya uygun olanlar ön-işleme anlamında kullanılabilir. Uygun ön-işleme prosedürlerinin uygulanması, öznitelik çıkartma ve sınıflandırma işlemlerinin doğru bir şekilde yapılabilmesine imkân tanımaktadır.

2.1.1. Anomali giderme

Bir rastgele değişken için ortalama değerinin çok uzağında yer alan değerlere sahip veriler anomali (outlier) olarak değerlendirilmektedir. Anomaliler, sınıflandırma uygulamalarının eğitim aşamasında yüksek seviyeli hataların oluşmasına ve karar yüzeylerinin problemleri bir şekilde tasarlanmasına neden olmaktadır. İstenmeyen veri karakteristiğine sahip oldukları için anomalilerin özellikle yüksek gürültülü saha ölçümleri durumlarında giderilmesi büyük önem taşımaktadır. Anomali verisinin belirlenmesi aşamasında farklı kurallar uygulanabilmekle birlikte, normal dağılım sergileyen değişkenler için ortalama değerden, standart sapmanın 1, 2 veya 3 katı kadar sapan değerler anomali olarak değerlendirilebilmektedir [58]. Alınan menzilin

profillerinde, sınıflandırmaya uygun olmayan profillerin ayıklanmasına yönelik olarak anomali profil belirleme çalışması yapılmıştır. Bu doğrultuda, profili elde edilen her bir gemi sınıfı için profillerden gemi boyu bilgisi hesaplanmıştır. Bununla birlikte, elde edilen boy bilgilerine yönelik olarak orta değer ve standart sapma gibi istatistiksel parametrelerin kestirimi yapılmıştır. Son aşamada ise, her bir gemi sınıfı için, boy bilgisi sınıfa ilişkin orta boy ile standart sapmanın belirli bir katının toplamından büyük olan profiller anomali profil olarak değerlendirilmiş ve sınıflandırma işlemlerine dahil edilmemiştir. Örneğin, sivil balıkçı sınıfına ilişkin boy bilgisinin orta değeri yaklaşık 31 m, standart sapması ise yaklaşık 5 m olarak hesaplanmıştır. Bu durumda, standart sapma çarpan değerinin 2 olarak seçilmesi neticesinde, elde edilen profiller içerisinde boy bilgisi 21 m'den az veya 41 m'den fazla olan profiller balıkçı sınıfı için anomali profil olarak belirlenmiştir. Şekil 2.1 şeklinde örnek bir hedefe ait hız ve bakış açısı öznitelikleri bakımından anomali inceleme çalışması sergilenmiştir. İlgili hedef tipine ait hız ve bakış açısı özniteliklerinin önceden belirlen kabul edilebilir değer aralığında olup olmadığı kontrolü gerçekleştirilmiş ve kabul sınırları dışında kalan veriler anomali olarak kabul edilmiştir.



Şekil 2.1. Hız ve bakış açısı öznitelikleri için anomali giderme işlemi

2.1.2 Veri normalizasyonu

Hedef sınıflandırma uygulamalarında, özellikle farklı sınıflara ait öznitelik değerlerinin farklı dinamik aralıklarda seyretmesi durumlarında veri normalizasyonu işlemi sıklıkla kullanılmaktadır. Veri normalizasyonu işleminin uygulanmadığı durumlarda yüksek değerli özniteliklerin sınıflandırıcı tasarımı aşamasında maliyet fonksiyonunu (cost function) domine etmesi problemi söz konusu olmaktadır. Normalizasyon işlemi, tüm özniteliklerin önceden tanımlı bir değer aralığında kalmasını garanti etmektedir.

Normalizasyon anlamında yaygın biçimde kullanılan bir metodoloji, doğrusal yöntemler kullanarak özniteliklerin sıfır ortalama ve birim değişinti sunacak biçimde normalize edilmesidir. İlgili metodolojiyi örneklemek üzere elimizde özel bir x özniteliğinin N adet değerinin olduğunu varsayalım. Bununla birlikte, ilgili özniteliğe ilişkin tüm sınıflardan elde edilen değerlerden kestirilen ortalama değeri \bar{x} , standart sapma değerini ise σ ile gösterelim. Bu durumda, belirtilen sınıfa ilişkin öznitelik değer aralığı;

$$\hat{x}_1 = \frac{x_i - \bar{x}}{\sigma}, i = 1, 2, \dots, N \quad (2.1)$$

biçiminde olacaktır. Burada \hat{x}_1 ile normalize öznitelik değeri gösterilmektedir.

Alternatif bir biçimde, öznitelik değerlerinin $[-1, +1]$ gibi belirli bir değer aralığında olması da sağlanabilir. Uygulanabilecek üçüncü bir yaklaşım ise doğrusal olmayan normalizasyon yöntemidir. “Softmax”, doğrusal olmayan optimizasyon yöntemine örnek olarak verilebilmektedir ve

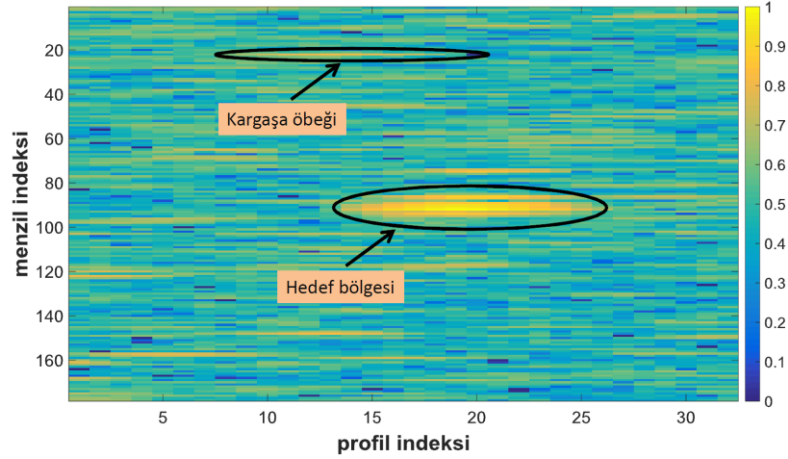
$$\hat{x}_1 = \frac{1}{1 + \exp(-y)}, y = \frac{x_i - \bar{x}}{r\sigma} \quad (2.2)$$

formülasyonu ile ifade edilebilmektedir. Burada r kullanıcı tanımlı bir sıkıştırma parametresidir. Denklem (2.2) ile verilen fonksiyon sayesinde öznitelikler $[0-1]$ aralığına doğrusal olmayan bir biçimde transfer edilebilmektedir.

2.1.3. Kargaşa giderme

Kargaşa, herhangi bir radar sistemi için istenmeyen veri veya hedef anlamına gelmektedir ve sistemlerin sağlıklı bir şekilde hizmet verebilmesi için radar verilerindeki kargaşanın etkin bir biçimde giderilmesi gerekmektedir. Kargaşa verisinin giderilmesi aşamasında, kargaşanın zamansal, uzamsal veya spektral karakteristiklerine göre birçok farklı yöntem uygulanabilmektedir. Verinin uzamsal karakteristiği göz önünde bulundurularak eşikleme, lokal olmayan ortalamalar (Non-Local Means, NLM) algoritması ile ara değerlendirme ve uzamsal filtreleme yöntemlerinin kullanılması yoluyla kargaşa giderimi gerçekleştirilmiştir.

Örnek bir profil verisi Şekil 2.2 şeklinde verilmektedir. Gemi hedefi bölgesinin belirli bir yanca açısı boyunca taranması yolu ile elde edilen profil verisinde hedefin bulunduğu bölge eliptik bir geometrik çizim ile işaretlenmiştir. Burada verilen örnek şekil incelendiğinde, profil verisinde kenar bölgelerin değişen genlik seviyeli kargaşa bilgisi, yaklaşık olarak orta bölgenin ise yüksek seviyeli gemi hedefi bilgisini barındırdığı görülmektedir. Bu bilgiler ışığında, kargaşa giderme anlamında uygulanabilecek yöntemlerden bir tanesi olarak, profil verisinin kenar bölgelerindeki değerlerin kullanılması ile elde edilen ortalama kargaşa seviyesine göre verinin eşiklenmesi akla gelmektedir. Bu doğrultuda, hesaplanan eşik değerinin altında kalan değerlerin sıfır değerine çekilmesi ile gerçekleştirilen “eşikleme” işlemi sonrası verideki kargaşa belirli bir oranda azaltılmış olacaktır. Kargaşa bölgesindeki anlık yüksek seviye geçişlerini önlemek ve bununla birlikte hedef verisi bölgesini belirginleştirmek üzere eşiklemeye ilave olarak ara değerlendirme işlemi uygulanabilmektedir. Ara değerlendirme sonrasında, işlenmiş profil verisi üzerinde gemi hedefinin bulunduğu bölgenin veri öbeği biçiminde belirginleşmesi, kargaşa bulunan bölgelerin ise düşük seviyelerde seyretmesi beklenmektedir. Bununla birlikte, yüksek seviyeli kargaşa bölgelerinde de gemi hedefi bölgesine göre uzamsal olarak daha küçük bir bölgede yoğunlaşmış kargaşa öbekleri belirebilmektedir.



Şekil 2.2. Örnek menzil profili verisi

İstenmeyen kargaşa öbeklerinin giderilmesi anlamında iki ayrı yöntem başvurulmaktadır. Bu yöntemlerden birincisi, öbeklerin oluştuğu konumun profil verisi merkezine olan uzaklığının hesaplanması ve ilgili uzaklığın belirli bir değerin üzerinde olması durumunda öbek bölgesindeki verinin sıfıra eşitlenmesidir. Kargaşa

öbeklerinin giderilmesi için uygulanan ikinci yöntem ise uzamsal filtreleme yöntemidir. Şöyle ki; gerçek gemi hedefleri Şekil 2.2 şeklinde de görüldüğü gibi uzamsal iki boyutta da belirli mesafelerde süreklilik gösterirken, kargaşa öbekleri ise aynı karakteristiğe genel olarak sahip olmamaktadır. Bu doğrultuda, bir kayan pencere içerisinde her iki uzamsal boyut için belirli değerlerin altında sürekliliğin olduğu bölgeler de yine kargaşa öbeği olarak değerlendirilebilmekte ve ilgili bölgelerdeki değerler sıfıra eşitlenmektedir. Kargaşa giderme anlamında uygulanan adımlar sırası ile:

- Kargaşa seviyesi hesabı,
- Kargaşa seviyesine göre eşikleme,
- İnterpolasyon,
- Uzamsal filtreleme

olarak sıralanabilmektedir. Burada sıralanan adımlar, profil verisindeki kargaşa seviyesine ve hedef bölgesindeki ortalama değer seviyesinin kargaşa bölgesindeki seviyeye oranına göre yinelemeli olarak tekrarlanabilmektedir. Bununla birlikte, profil verisinin kenar bölgelerindeki değerlerden hesaplanan kargaşa seviyesinin hedef bölgesindeki ortalama seviyeye göre göreceli olarak yüksek olması durumunda ise yukarıdaki adımlar kargaşa giderimini sağlamamaktadır. Böyle durumlarda, profil verisinin sınıflandırmaya uygun olmadığı değerlendirilmekte ve söz konusu yüksek kargaşaya sahip veri sınıflandırma işlemlerine dahil edilmemektedir.


Yukarıda sıralanan kargaşa giderme adımlarından biri olan ara değerlendirme işlemi, gürültü ve/veya kargaşa bastırma amaçlı olarak uygulanabilen NLM algoritması kullanılarak gerçekleştirilmektedir. NLM ara değerlendirme algoritmasında, herhangi bir test pikselinin değeri, ilgili piksele bir pencere dahilinde yakın olan piksellerin değerlerinin test piksele olan komşuluk benzerliği dikkate alınarak ağırlıklı olarak toplanması ile güncellenmektedir. NLM yaklaşımı ve bu yaklaşım ile ilgili formülasyonları anlamlandıran şematik gösterim Şekil 2.3 şeklinde verilmektedir.

Değeri güncellenecek olan örnek piksel Şekil 2.3 şeklinde kırmızı ile gösterilmektedir. Şekilde siyah karesel geometri ile gösterilen alan ise, test pikselin güncellenmesinde kullanılacak olan piksellerin bulunduğu pencereyi temsil etmektedir. Güncelleme için, pencere içerisinde yer alan tüm piksellerin test pikseli ile komşuluk benzerliği dikkate alınacağı için, metodun uygulama aşamasının

başlangıcında görüntü verisi üzerindeki tüm pikseller için komşuluk vektörleri oluşturulmaktadır. Komşuluk vektörü $k \times k$ uzunluklu olmak üzere test pikseli için;

$$N_i = [a_1, a_2, \dots, a_{k \times k}]^T \quad (2.3)$$

biçiminde oluşturulmaktadır. Burada k , komşuluk penceresine ait her iki kenarın piksel uzunluğunu temsil etmektedir.



Şekil 2.3. NLM Ara değerlendirme yaklaşımı

Komşuluk vektöründe bulunan a değerleri, test pikselinin komşuluk penceresi içerisinde yer alan piksel değerleridir. N_j test pikseline komşu herhangi bir pikselin komşuluk vektörü olmak üzere, i ve j pikselleri arasındaki uzaklık katsayısı;

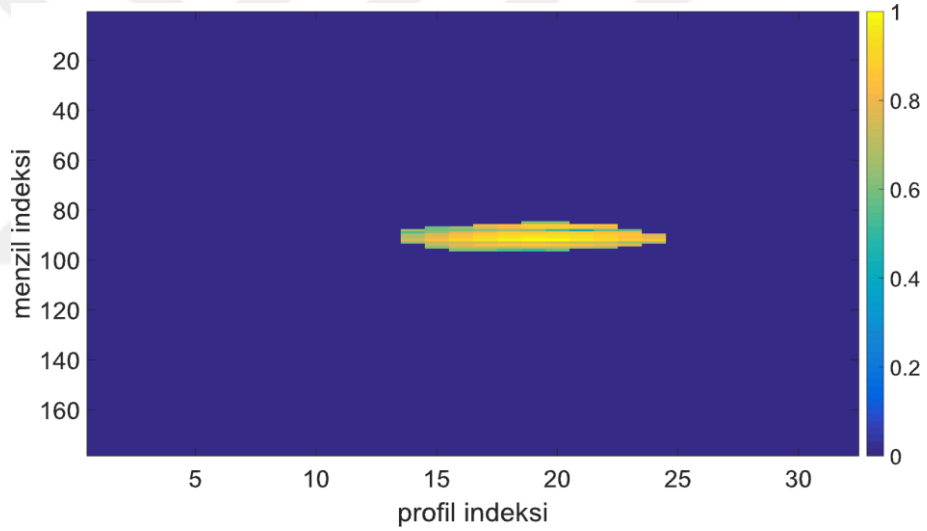
$$w_{ij} = \exp\left(-\frac{1}{h^2} \|N_i - N_j\|^2\right) \quad (2.4)$$

olarak hesaplanmaktadır. Bu denklemde, h ile filtre derecesi temsil edilmektedir. Tüm uzaklık katsayıları hesaplandıktan sonra, u_j pencere içerisindeki komşu pikselleri göstermek üzere, (2.5) formülasyonu kullanılarak test pikselinin güncel değeri hesap edilmektedir. Ayrıntıları verilen NLM algoritması, herhangi bir pikselin güncellenen değerini hesaplarken sadece konumsal yakınlığı değil, uzamsal benzerliği de dikkate almaktadır. Bu sayede, kargaşa içerisindeki anlık yüksek

seviyeli genlik değerlerinin olumsuz etkisi bastırılmakta, bununla birlikte, özellikle gerçek hedeflerin bulunduğu yüksek genlik seviyeli bölgenin etrafından ayrılarak belirginleşmesi sağlanmaktadır. Örnek profil verisine belirtilen kargaşa giderme adımlarının uygulanması sonrası elde edilen kargaşası giderilmiş profil verisi Şekil 2.4 şeklinde gösterilmektedir.

$$\hat{x}_1 = \frac{\sum_j w_{ij} u_j}{\sum_j w_{ij}} \quad (2.5)$$

Şekil 2.4 şeklinde görüldüğü üzere, ham profil verisinde bulunan kargaşa, eşikleme, NLM algoritması ile ara değerlendirme ve uzamsal filtreleme adımları sonrasında giderilmiş ve sınıflandırma işlemlerinde kullanmaya hazır bir profil verisi elde edilmiştir.



Şekil 2.4. Kargaşası giderilmiş menzil profili verisi

2.1.4. Öznitelik çıkartımı

Hedef sınıflandırma uygulamalarında en önemli aşamalardan bir tanesi özniteliklerin çıkartılması aşamasıdır. Çıkartılan özniteliklerin kalitesi sınıflandırma performansına doğrudan etki etmektedir. Bu işlemin uygulanmasındaki asıl amaç, eldeki ham verinin, sınıflandırma işlemi için oluşturulacak karar yüzeylerinin en iyi ve keskin bir biçimde oluşturulmasını sağlamak amacıyla uygun bir uzaya transfer edilmesidir.

Birinci bölümde de ayrıntılı bir biçimde anlatıldığı gibi, gemi hedefi sınıflandırma uygulamalarında, farklı gemi sınıflarını birbirlerinden ayırt edebilmek üzere farklı

öznitelik uzaylarından yararlanıldığı bilinmektedir. İlgili öznitelik uzayları, sınıfları ayırt edebilme kapasitesi, hesaplama süresi, bilgisayar hafızası gereksinimi veya eldeki ham veriye uygulanabilirlik gibi birtakım açılardan birbirlerinden farklılıklar sergilemektedir.

Literatürde dikkate alınmış olan öznitelik uzayları içerisinde, gemi hedefi sınıflandırmada yüksek performans sunmuş olanlardan, menzil profil verisinin sınıflandırılması çalışmalarında yararlanılmıştır. Bu doğrultuda, uzamsal öznitelik bilgileri kullanılarak sınıflandırıcı yapıları için girdiler elde edilmiştir.

Gemi hedefi sınıflandırma uygulamalarında boy, kütle merkezi, simetri veya en güçlü yansıtıcının konumu gibi uzamsal özniteliklerden yararlanılabilmektedir. Uzamsal özniteliklerin bir kısmı ele alınan menzil profilinin ait olabileceği sınıf sayısını azaltabilirken, bir kısmı sınıflara yönelik genel bir özelliği temsil edebilmektedir. Örnekle açıklamak gerekirse, boy uzamsal özniteliği ile eldeki profilin ait olabileceği sınıf sayısını indirmek mümkündür. Bununla birlikte, genel olarak 200 m ve altı uzunluktaki gemilerden askeri olanların simetrik olduğu ön bilgisi altında, simetri özniteliğinden sivil-askeri ayırımında yararlanılabilmektedir. Elde edilen menzil profillerinin sınıflandırılması işlemlerinde ve saha verisi ile sentetik verilerin uygunluğunun yapıldığı analizlerde, literatürde sıklıkla kullanılan yedi farklı uzamsal öznitelik dikkate alınmıştır. Bu bölüm altında, boy, tepe sayısı, en yüksek tepe konumunun uzaklığı, en yüksek iki tepe arası mesafe, simetri, dağınıklık (dispersant) ve kütle merkezi olmak üzere yedi uzamsal özniteliğe ilişkin genel bilgiler verilmektedir.

Boy bilgisi, gemi hedefi sınıflandırma çalışmalarında ilk olarak hesaplanan parametrelerden olmakta ve büyük önem arz edebilmektedir. Özellikle ele alınan bir profil verisinin ait olabileceği sınıf sayısını düşürme anlamında veya benzer biçimde, sınıflandırma sonuçlarına ilişkin güven parametresi belirleme aşamalarında boy bilgisi yaygın olarak kullanılmaktadır. Menzil profillerinde boy hesaplaması yapılırken öncelikli olarak menzil profilinde anlamlı verinin bulunduğu (menzil profilinde '0' dan büyük değer alan) indisler bulunur. Böylelikle "anlamlı profil verisi" elde edilmiş olur. Örneğin, Şekil 2.4 şeklinde verilen kargaşası giderilmiş profil verisinde anlamlı veri 66 ile 98 arası menzil indislerinde yer almaktadır.

Anlamli verinin bulunduđu menzil indisi sayisi (M), indislere karřılık gelen menzil cözünürlüđü deđer (R_{res}) ve radar-hedef bakıř açısı (α) bilgileri kullanılarak,

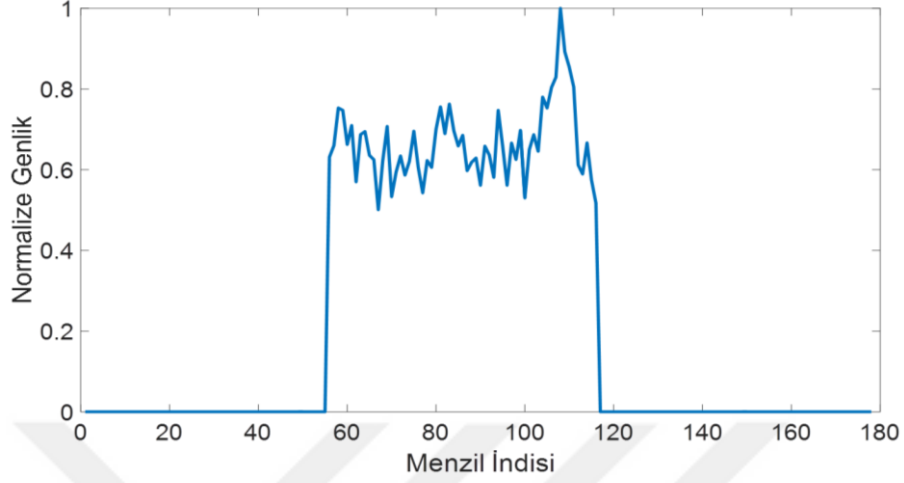
$$L = \frac{M \cdot R_{res}}{\cos \alpha}, [m] \quad (2.6)$$

biçiminde gemi hedefleri için boy hesabı (L) yapılmaktadır. Temsili olarak verilen menzil profili için boy deđer 114 m olarak hesaplanmıřtır.

Tepe sayisi bilgisi, bir menzil profilindeki genel saçııcı bölge miktarı hakkında fikir verebilmektedir. Örnek vermek gerekirse, balıkçı gibi görelili olarak küçük gemi sınıflarında az sayıda saçııcı bölge bulunabilmekteyken, kruvazör gibi silahlı büyük askeri gemiler çok sayıda genel saçılma bölgesine sahip olabilmektedir. Saçııcı bölge sayisi anlamında ayırt edici bilgi sađlayan tepe sayisi özniteliđi hesaplanırken, menzil profilindeki anlamli menzil indisi aralıđındaki veride sađ ve sol indislerine göre daha yüksek genlik deđerine sahip menzil indislerinin sayisi toplanarak tepe sayisi deđerine ulařılmaktadır. Temsili menzil profili için bu deđer 9 olarak hesaplanmıřtır.

Askeri gemilerin çođunda (özellikle 200 m ve altındaki askeri gemiler özelinde), ana saçııcı bölgeler geminin orta kısmında yer almaktadır. Diđer taraftan, ařađıdaki Şekil 2.5 řeklinde de görüldüđü gibi özellikle taşıma amaçlı kullanılan sivil gemilerde ise baskın yansıtıcılar geminin ön veya arka ucuna yakın konumlarda bulunmaktadır. Dolayısı ile askeri-sivil gemi ayırımı açısından en yüksek genlikli tepenin konumu yarar sađlayabilmektedir. Bu öznitelik hesaplanırken, [0,1] aralıđına normalize konum bilgisi hesaplanmaktadır. Bununla birlikte, profildeki anlamli menzil aralıđındaki veri için, en yüksek genliğe sahip tepe konumunun geminin en önünde bulunması durumunda bu öznitelik '0', ortasında bulunması durumunda '0.5' ve en arkasında bulunması durumunda ise '1' deđerini alacaktır. Bu dođrultuda, ilgili öznitelik deđer 2.5 řeklindeki gibi özellikle yük taşıyan sivil gemiler için ise '0' veya '1' civarında deđerler almaktadır. En yüksek genlikli iki tepe arası mesafe özniteliđi en yüksek genlikli tepe konumu özniteliđine benzer biçimde hesaplanmaktadır. Anlamli menzil indisleri arasındaki profil verisinde en yüksek genliğe sahip iki tepe konumu arası [0,1] aralıđına normalize olarak hesaplanmaktadır. Şöyle ki; örneđin en yüksek genlikli iki tepe konumundan bir

tanisinin profil verisinin en başında, diğerinin ise verinin en sonunda olması durumunda bu öznelik '1' değerini alacaktır.



Şekil 2.5. Tanker sınıfı temsili menzil profili

Simetri özneliği, feribot gibi özel bazı gemi sınıfları veya genel anlamda askeri-sivil gemi ayrımı açısından ayırt edicilik sağlayabilmektedir. Anlamli profil verisinin tam orta konumuna göre sağ ve sol tarafta kalan konumlara ilişkin toplamsal güç değerlerinin oranı olarak ifade edilen simetri özneliği;

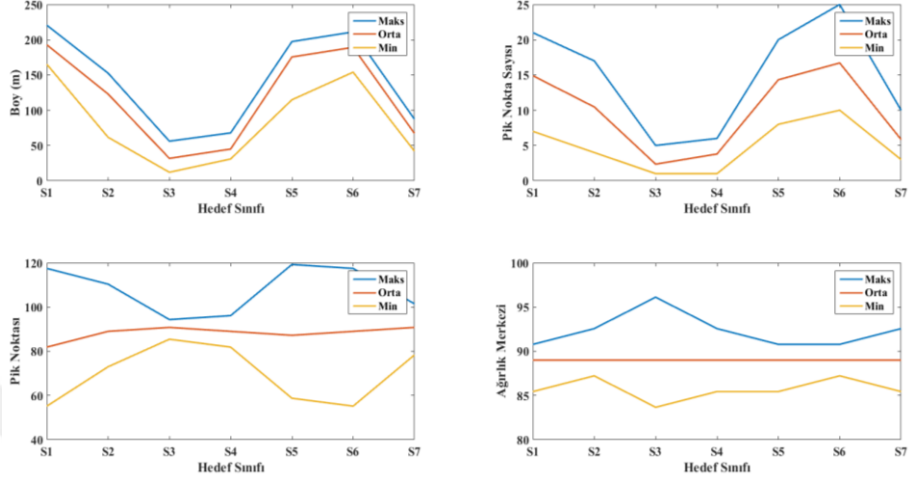
$$S = \frac{\left(\sum_{n=1}^M |RP(n)|^2 \right)}{\left(\sum_{n=\frac{M}{2}+1}^M |RP(n)|^2 \right)} \quad (2.7)$$

biçiminde hesaplanmaktadır. Eşitlik (2.7) ile, RP(n) ile anlamli profil verisi, M ile anlamli profil verisindeki menzil indisi sayısı ve S ile ise simetri özneliği temsil edilmektedir. Simetri özneliği, yüksek simetri özelliği sergileyen profiller için '1' e yakın değerler almaktadır.

$$CM = \frac{\left(\sum_{n=1}^M n \cdot |RP(n)| \right)}{\left(\sum_{n=1}^M |RP(n)| \right)} \quad (2.8)$$

Kütle merkezi özneliği ile anlamli profil verisinin [0,1] aralığına normalize edilmiş ağırlık merkezi ifade edilmektedir. Bu öznelik, tanker gemilerinde olduğu gibi profil üzerinde saçıcıların belirli bir bölgede yoğunlaştığı durumlarda ayırt edicilik

sunabilmektedir. Kütle merkezi özneliği denklem (2.8) ifadesi ile hesaplanmaktadır. Denklem (2.8) ifadesinde CM ile kütle merkezi özneliği temsil edilmektedir.Öznitelik çıkartımı işlemi kapsamında çalışılan hedeflere ait elde edilen özneliklerin örnek görüntüsü Şekil 2.6 şeklinde sergilenmektedir.



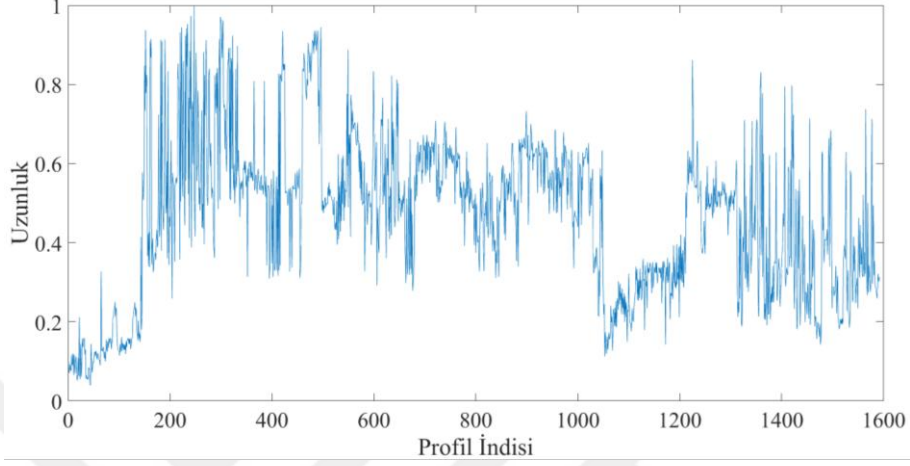
Şekil 2.6. Çıkarılan özneliklerin sınıf bazlı olarak sergilenmesi

2.1.5. Öznelik etki analizi sonuçları


Daha önceki bölümlerde de anlatıldığı üzere tez çalışması kapsamında sınıflandırma sürecinde başarıyı artırması amacıyla 6 farklı öznelik kullanılmıştır. Kullanılan öznelikler sırasıyla boy, en yüksek genlik değerinin uzaklık bilgisi, iki farklı en yüksek genlik değerinin uzaklığı, menzil profilindeki pik noktası sayısı, simetri bilgisi, yansıtıcılık değeri olmak üzere hedef fiziki özellikleri ve yansıtıcılık değerlerinin çıktılardan oluşan bir kümedir. Özneliklerin başarıya olan etkisini incelemek amacıyla bir MATLAB fonksiyonu olan FSCNCA (Feature Selection Using Neighborhood Component Analysis) bileşeni kullanılmıştır [59][59]. FSCNCA metodu eğitim ve test verisi bilgilerini kullanarak analizlerini gerçekleştirmektedir. Öznelik ağırlıklandırma çalışmalarında en yakın komşuluk (nearest neighbour (NN)) sınıflandırıcı üzerine kurulmuş bir sınıflandırma mimarisi mevcuttur. Dahili sınıflandırma algoritması kullanılarak her test özneliğinin eğitim özneliklerine benzerlik olasılıkları üretilir.

Üretilen olasılık değerlerinin toplamının 1 olması beklenir. Ayrıca, metot girdilerinden olan λ değerinin optimizasyonu için bir ön çalışma yapılması gerekmektedir. λ parametresi düzenleme (regularization) parametresi olarak

tanımlanmıştır. Kullanıcı tarafından belirlenen aralıkta λ -loss değerleri üretilir. En düşük sınıflandırma kaybı üreten λ değeri için işlem tekrarlanır ve öznelik ağırlık grafiği elde edilir. Ağırlık değeri sıfıra yakın olanların sınıflandırma başarımına etkisi olmadığı sonucuna varılır.



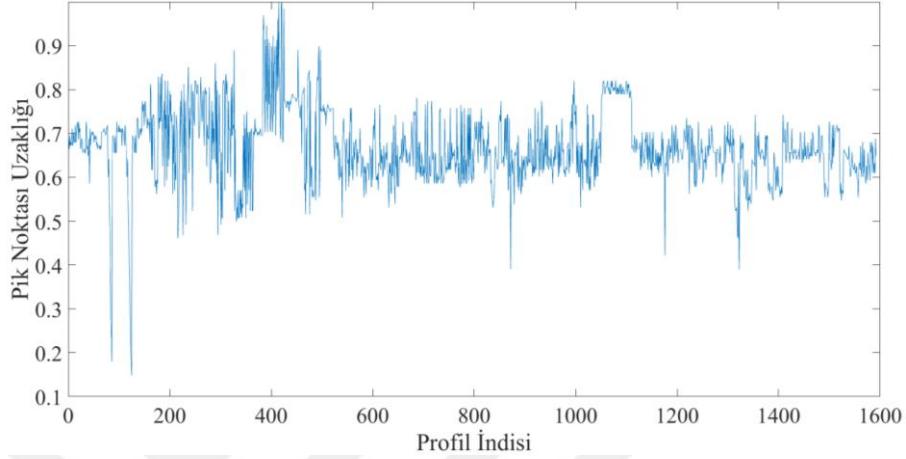
Şekil 2.7. Hedefe ait uzunluk değerinin (normalize) menzil profili kümesi içerisindeki dağılımı



Şekil 2.8. Boy özneliğinin hedef tiplerine göre dağılımı

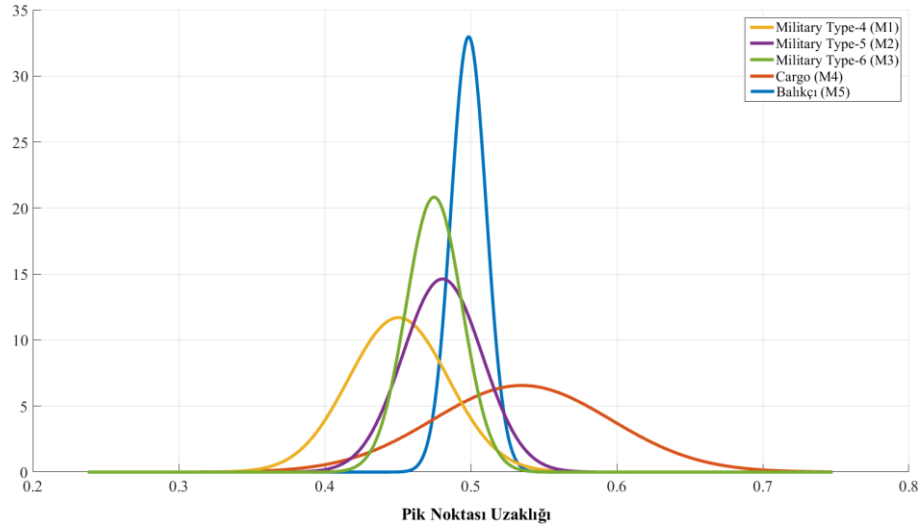
Hangi özneliğin sınıflandırma başarımında daha etkili olduğu konusunda yapılan araştırma sonuçları aşağıda incelenmiştir. Şekil 2.7 şeklinde hedefe ait uzunluk bilgisinin menzil profili kümesindeki dağılımı gözlemlenmektedir. Menzil profillerinin sınıflara göre boy özneliği bakımından tekil olarak dağılımları Şekil 2.8 şeklinde görselleştirilmiştir. Şekilden de anlaşılacağı üzere boy değeri en küçük sınıf balıkçı, en büyük sınıf ise kargo hedef sınıfıdır. Askeri hedeflerin boy özneliği bakımından birbirine yakın özellikler sergilerikleri gözlemlenmektedir. Yapılan

literatür çalışmaları ve elde edilen verilerin incelenmesi sırasında hedeflere ait en yüksek genlik değerinin konumlandığı noktanın başlangıç noktasına uzaklığı farklı hedef tiplerine göre değişiklik gösterebildiği gözlemlenmiştir. Menzil profillerindeki pik noktası uzaklığının sergilendiği grafik Şekil 2.9 şeklinde gözlemlenmektedir.



Şekil 2.9. Hedefe ait pik noktası mesafesi değerinin (normalize) menzil profili kümesi içerisindeki dağılımı

Ayrıca, pik noktası uzaklığı özneliğinin hedefler bazında gruplanarak görselleştirilmesi Şekil 2.10 şeklinde gösterilmiştir.




Şekil 2.10. Hedefe ait pik noktası mesafesi değerinin (normalize) hedef tiplerine göre dağılımı

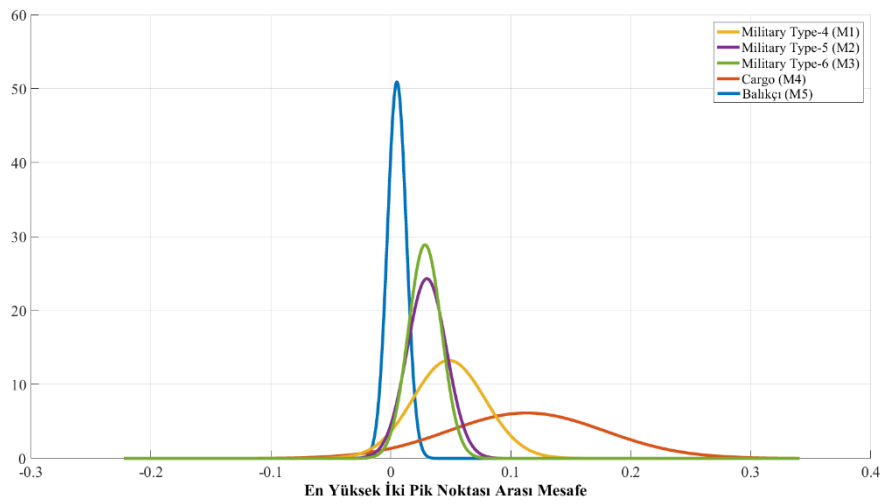
Şekilden de anlaşılacağı üzere pik noktası uzaklığı, yani en yüksek yansıtıcı bölgenin bulunduğu noktanın konumu askeri hedeflerde burun kısmına daha yakın bölgelerde yer almaktadır. Sivil hedefler için en yüksek yansıtıcı bölge merkeze yakın

konumlanmıştır. Askeri ve sivil hedeflerin fiziksel özelliklerindeki farklılıklar hakkında bilgilendirici bilgi yansıtıcı bölgelerin konumlandığı alanlardan elde edilebilmektedir. En yüksek yansıtıcının konumlandığı ve en yüksek genlik değerinin elde edildiği konum bilgisini veren pik noktası uzaklığı özneliğinin sivil ve askeri olmak üzere farklı hedefler bakımından dağılımı Şekil 2.10 şeklinden incelenebilmektedir.


Hedefe ait belirlenen özneliklerden bir diğeri ise hedefe ait en yüksek iki genlik noktası arasındaki mesafe bilgisidir. Özellikle sivil hedefler ile askeri hedeflerin ayrıştırılmasında önemli rol oynayacağı düşünülerek seçilmiştir.



Şekil 2.11. Hedefe ait en yüksek iki genlik noktası arasındaki mesafe değerinin (normalize) menzil profili kümesi içerisindeki dağılımı



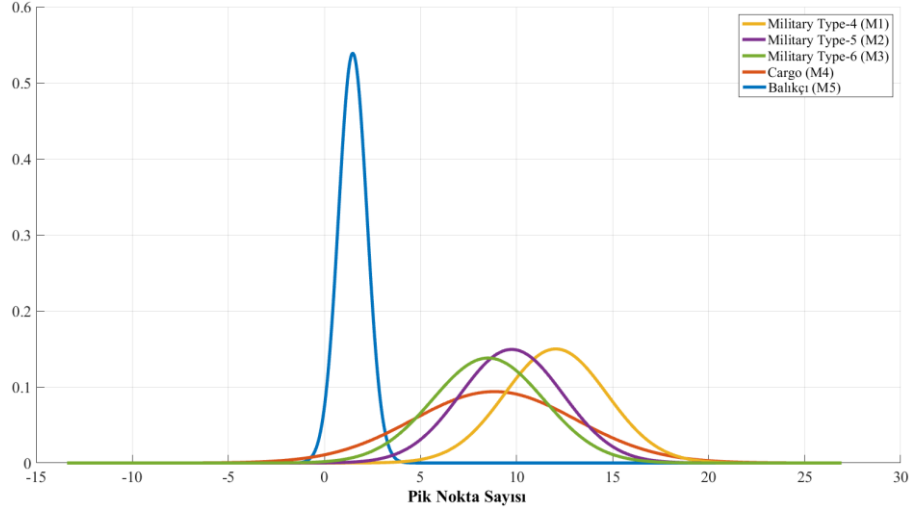
Şekil 2.12. Hedefe ait en yüksek iki genlik noktası arasındaki mesafe değerinin (normalize) hedef tiplerine göre dağılımı




Şekil 2.13. Hedefe ait yüksek genlikli nokta sayısı değerinin (normalize) menzil profili kümesi içerisindeki dağılımı

İki en yüksek genlik arası mesafenin normalize olarak sergilediği öznelik kümesinin grafiksel olarak gösterimi Şekil 2.11 şeklinde sergilenmektedir. Hedefe ait en yüksek iki genlik noktası arası mesafe özneliğinin hedefler bazında gruplanarak görselleştirilmesi Şekil 2.12 şeklinde gösterilmiştir. Özellikle askeri hedeflerin yapısal benzerliklerinden dolayı bu öznelik bakımından benzer karakter sergilediği gözlemlenmiştir. Belirlenen özneliklerden bir diğeri ise hedefe ait yüksek genlikli nokta sayısı bilgisidir. Hedeflerin ayrıştırılmasında önemli rol oynayacağı düşünülmüş ve seçilmiştir. Belirlenen eşik değerinin üzerindeki genlik değerlerinin sayısı öznelik olarak oluşturulmuştur. İlgili özneliğe ait gösterim Şekil 2.13 şeklinde sergilenmektedir. Yüksek genlikli nokta sayısı bilgisi, hedef üzerindeki yansıtıcı yüzey sayısı hakkında da bilgi vermektedir. Fiziksel olarak birbirinden farklı yapılar sergileyen hedeflerin ayrıştırılmasında katkı sağladığı düşünülmektedir.

Yüksek genlikli nokta sayısının hedef tipi özelinde gruplanarak sergilenmesi Şekil 2.14 şeklinde gösterilmiştir. Askeri ve sivil hedefler bazı durumlarda fiziksel olarak farklılık sergileyebilir. Örneğin askeri hedeflerin çoğunda en yüksek yansıtıcıların konumu menzil profilinin merkezinde toplanmaktadır. Sivil hedeflerde ise en yüksek yansıtıcılar menzil profilinin başında veya sonunda bulunabilir. Hatta bazı yük taşıyan sivil hedeflerin tam yük ile donatıldığı durumlarda yansıtıcılar homojen olarak dağılım gösterebilir. Bu bilgiler ışığında yüksek yansıtıcıların menzil profilinin neresinde konumlandığı bilgisini içeren simetri bilgisi öznelik olarak çıkarılmıştır.



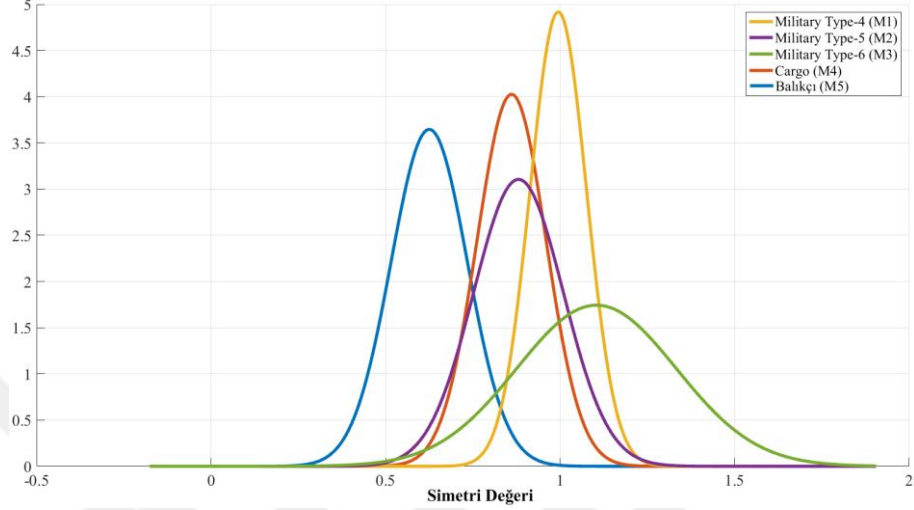
Şekil 2.14. Hedefe ait yüksek genlikli nokta sayısı değerinin (normalize) hedef tiplerine göre dağılımı



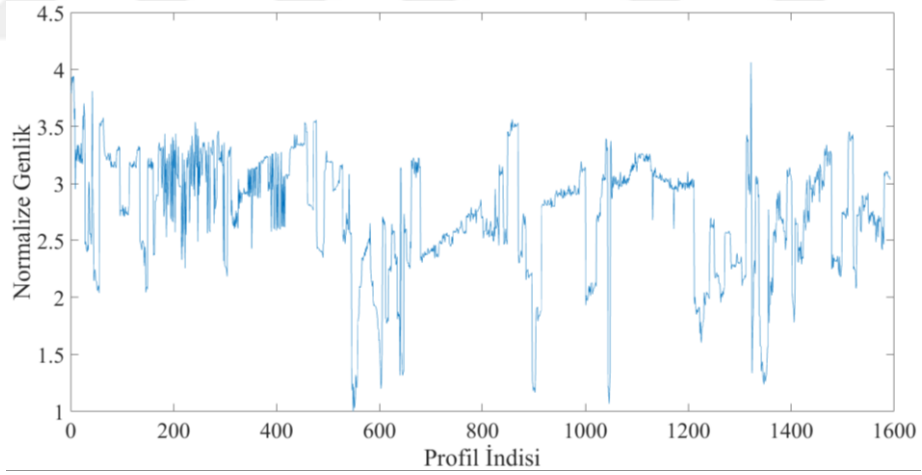
Şekil 2.15. Hedefe ait simetri değerinin (normalize) menzil profili kümesi içerisindeki dağılımı

Elde edilen simetri bilgisinin normalize olarak sergilediği ve elde edilen her profil için dağılımının gösterildiği Şekil 2.15 şekli, bahsi geçen öznitelik bakımından faydalı fikirler sunmaktadır. Simetri özneliğinin hedef tiplerine göre ayrıştırılarak görselleştirilmesi Şekil 2.16 şeklinde sergilenmiştir. Menzil profili kütüphanesinde bulunan profiller hedefin tipine ve ortam şartlarına bağlı olarak farklı yansıtıcılık değerleri göstermektedir. Hedeften yansıyan gücü, hedefin yüzeyindeki yansıtıcı unsurlar, denizin ölçüm koşullarındaki durumu ve radar ile hedefin fiziksel konuşlanması gibi etkenlerden etkilenmektedir. Bu durumun yansıtıcılık değeri olarak öznitelik kümesine eklenmesinin ayrıştırıcı olacağı düşünülmüştür. Öznitelik olarak yansıtıcılık değerinin etkisinin incelenmesi amacıyla oluşturulan grafik Şekil

2.17 şeklinde görülmektedir. Her hedef, sınıfının özelliklerini taşıyan fiziki yapıları ve metaryali sebebiyle farklı yansıtıcılık seviyeleri göstermektedir. Hedef tiplerine bağlı olarak yansıtıcılık özneliğinin Şekil 2.18 şeklinde sergilendiği gözlemlenmektedir.



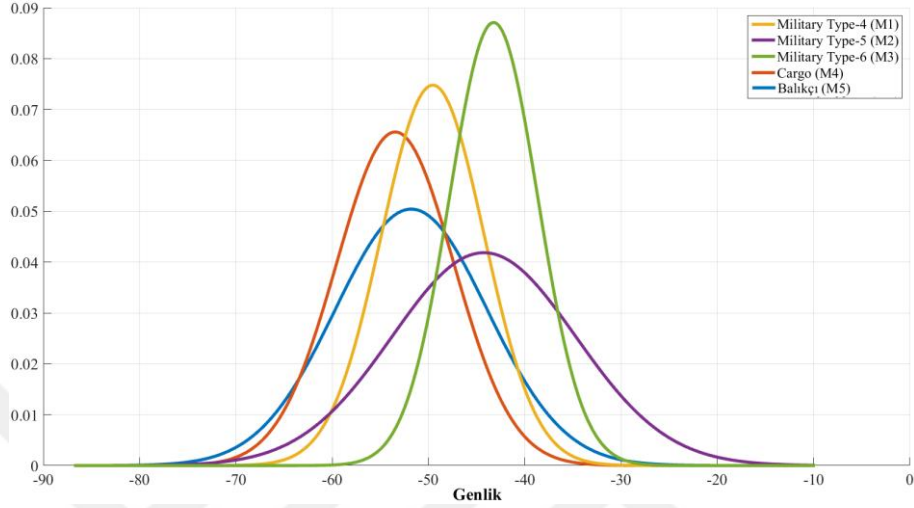
Şekil 2.16. Hedefe ait simetri değerinin (normalize) hedef tiplerine göre dağılımı



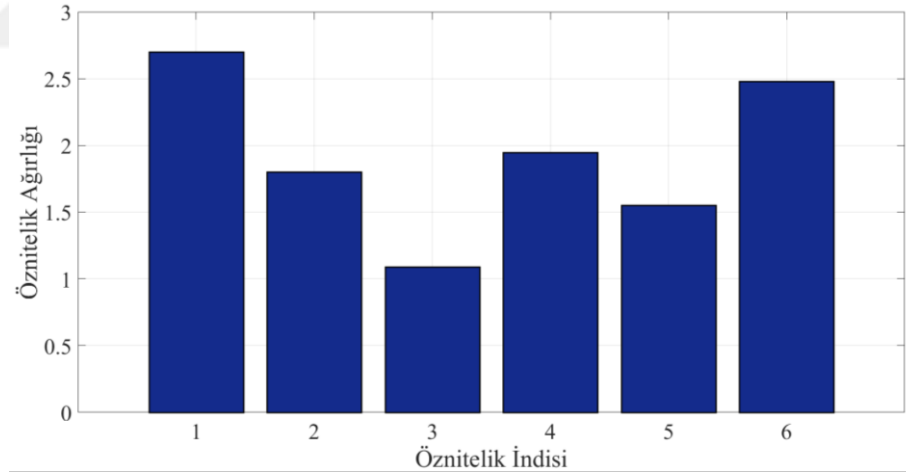
Şekil 2.17. Hedefe ait yansıtıcılık değerinin (normalize) menzil profili kümesi içerisindeki dağılımı

Tüm çıktılar ışığında belirlenen özneliklerin sınıflandırma başarımına etkisinin incelenmesi amacıyla çalışmalar gerçekleştirilmiştir. Gerçekleştirilen çalışma sonucunda elde edilen çıktılar Şekil 2.19 şeklinde sergilenmektedir. Şekilden de anlaşılacağı üzere grafikte 1. ve 6. öznelikler olarak sergilenen uzunluk ve yansıtıcılık değerlerinin en baskın öznelikler olduğu görülmektedir. Grafikte 3. sırada sergilenen ve en yüksek iki noktası arasındaki mesafenin öznelik olarak

değerlendirildiği durumun başarıma etkisi pozitif olmasına rağmen diğer öznelikler içerisinde en az etkiye sahip olduğu gözlemlenmektedir. Sınıflandırma başarıma özneliğin etkisini inceleyebilmek için verilerin tamamı yada bir alt kümesi kullanılarak FSCNCA yöntemi öznelik etki ölçümleri gerçekleştirilmiştir.



Şekil 2.18. Hedefe ait yansıtıcılık değerinin (normalize) hedef tiplerine göre dağılımı

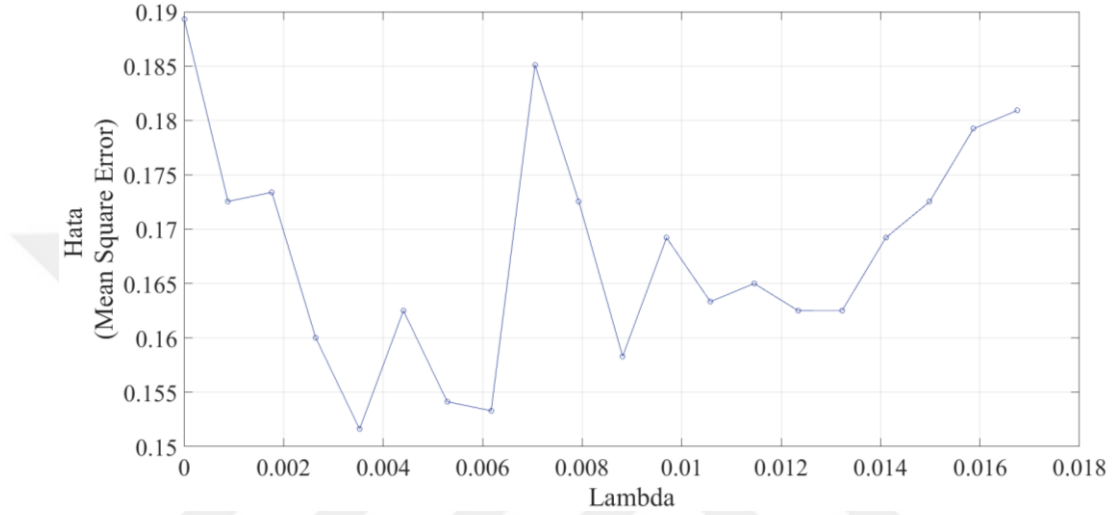


Şekil 2.19. Özneliklerin etki analizi sonucu ağırlıklandırılması

Bu yöntem kapsamına öncelikle eğitim ve test verilerine ihtiyaç duyulmaktadır. Öznelik seçiminde Neighborhood Component Analysis (NCA) kullanılmıştır. Her özneliğin ağırlığının bulunması sırasında ihtiyaç duyulan lambda değerinin elde edilmesi için farklı lambda değerleri için kayıp (loss) değerleri ölçülmüştür. Özneliğin başarılı bir şekilde ağırlıklandırılabilmesi için en az kayıp değerine sahip lambda değerinin kullanılması gerekmektedir. Çalışma sırasında en uygun lambda-

loss eşleşiminin bulunması için yapılan denemeler Şekil 2.20 şeklinde görsel olarak ifade edilmiştir.

Aşağıdaki şekilde elde edilen en az loss değeri üreten lambda değeri ile sınıflandırma ve öznitelik ağırlıklandırma çalışmaları gerçekleştirilmiştir. Öznitelik ağırlıklandırma çalışması sonucunda etkisiz bir öznitelik seçilmediği gözlemlenmiştir.



Şekil 2.20. Lambda-Loss grafiği

2.2. Sınıflandırma Algoritmaları

Hedef sınıflandırma çalışmalarında, ele alınan veriler, ön işleme, öznitelik çıkartımı veya boyut azaltımı gibi aşamalardan geçtikten sonra sınıflandırılma işlemine tabi tutulmaktadır. Sınıflandırma işlemi için, belirli bir miktarda eğitim verisi kullanarak, Bayes karar kuralı, bir maliyet fonksiyonunun minimizasyonu veya öbekleme gibi farklı olabilen prosedürler ile oluşturulan karar yüzeyleri dikkate alınmaktadır. İlgili karar yüzeylerine göre sınıflandırması yapılacak olan öznitelik verisi uygun sınıfa atanarak sınıflandırma işlemi tamamlanmaktadır. Basitten karmaşık yapılara kadar çok farklılık gösterebilen sınıflandırıcı yapılarından Bayes karar kuralı, k-en yakın komşuluk (k-nearest neighbor, k-NN), olasılıksal veya genel regresyon yapay sinir ağlarıyla birlikte konvolüsyonel sinir ağları tabanlı derin öğrenme (deep learning, DL) metodolojileri gemi hedefi sınıflandırma çalışmalarında kullanılmak üzere uygulanabilirliği test edilmiştir. Tez kapsamında geliştirilen AMPF yönteminin başarımları, test edilen sınıflandırma yöntemlerinden en başarılı bulunan 3 yöntemle gerçekleştirilmiştir. Sınıflandırma algoritmalarının başarımları ve hesaplama

süreleri Tablo 2.1 tablosunda sergilenmektedir. PNN, CNN ve YOLO algoritmaları tez kapsamında geliştirilen AMPF algoritmasının performans testlerinde kullanılmak üzere seçilmiştir.

Tablo 2.1. Sınıflandırma algoritmalarının çalışma performansı verileri

	Sınıflandırma Algoritması	Sınıflandırma Doğruluğu [%]	Eğitim Süresi	Tekil Sınıflandırma
1	PNN	81,03	272,72s	1,26s
2	GRNN	73,93	112,30s	1,28s
3	k-NN	73,88	39,63s	1,24s
4	YOLO	86,30	5sa 12dk 44s	1,46s
5	CNN	77,50	1sa 15dk 21,55s	1,63s

Yukarıdaki tabloda özetlendiği üzere tez kapsamında kullanılması planlanan sınıflandırma algoritmalarının performans testleri gerçekleştirilerek en başarılı üç farklı yöntem değerlendirmeye alınmıştır. Tabloda sınıflandırma performansı olarak tekil hedef sınıflandırma sonuçlarının doğru sınıfa atanma yüzdesi verilmektedir. Ayrıca performans karşılaştırmalarında ilgili hedef sınıflandırma algoritmalarının eğitim süreleri ile birlikte tek menzil profilini sınıflandırma süresi de verilmiştir. Tablo 2.1 tablosundaki performans çıktıları göz önüne alınarak sınıflandırma çalışmalarında PNN, CNN ve YOLO algoritmalarının kullanılması uygun bulunmuştur.

2.2.1. Yapay sinir ağları

Yapay sinir ağları (YSA), beyindeki sinirlerin çalışmasını taklit ederek sistemlere öğrenme, genelleme yapma, hatırlama gibi yetenekler kazandırmayı amaçlayan bilgi işleme sistemidir. YSA insan vücudundaki sinir sisteminin bazı fonksiyonlarını modelleyen ve bazı yeteneklerini yakalamak isteyen basit hesaplamalı birimlerinin (nöronlar) yoğun bir paralel dizisidir; başka bir deyişle, teorik hale getirilmiş zekâ ve beyin faaliyetlerinin fazlaca basite indirgenmiş matematiksel modelleridir. YSA, kesin kurallarla gösterimi zor olan, daha çok algılamaya yönelik bilgileri işlemekte kullanılır. Olayları genelleme yetenekleri, eksik, belirsiz, bozulmuş bilgileri işleyebilme ve esnek olarak çalıştırabilmeleri önemli özelliklerindedir. Bu ağlarda kullanılan basit işleme elemanları insan beyninin işleme elemanı olan nöronların

modelidir. İnsan sinir sisteminin problemleri çözebilmek için öğrenme özelliği olduğu gibi yapay sinir ağlarının da bu özelliği mevcut bulunmaktadır [60].

Yapay sinir ağları eğitici ve eğitici olmaya üzere iki şekilde modellenmektedir. Eğitici öğrenmede, ağa hem giriş hem de istenen çıkış bilgisi girilir. Her denemeden sonra ağ kendi çıkışını doğru cevaplarla karşılaştırır ve çıkış hatası kabul edilebilecek seviyeye ininceye kadar ağırlıklarını değiştirerek tekrarlama yapar. Eğitici öğrenmede hiçbir hedef vektörü yoktur. Giriş vektörü sisteme uygulanır ve sistem, girişin benzer veya ayrılan özelliklerinden yararlanarak “(muhtemelen eğitimden önce tahmin edilemeyen) uyumlu bir çıkış üretecek şekilde kendisini organize eder [76][61],[62].

YSA'nın bu bölümde tanıtılan özellikleri karmaşık problemleri çözebilme yeteneğini göstermektedir. Günümüzde birçok bilim alanında YSA, bundan sonraki bölümlerde anlatılacak özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur. YSA'nın temel işlem elemanı olan hücre ve bu hücrelerin meydana getirdiği ağ doğrusal değildir. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur. YSA'nın istenilen davranışı göstermesi için, hücreler arası doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerekmektedir. YSA örneklerle eğitilir ve ağırlık matrisindeki değerleri değiştirerek öğrenme işlemini tamamlar. Böylece ağa bir giriş uygulandığı zaman o girişe uygun çıkış cevabı üretilir. Genelleme yeteneği, ağın performansını göstermekte ve eğitim kümesinde mevcut olmayan durumlar için ne kadar iyi tahminlerde bulunabileceğini belirlemektedir. YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. YSA, çok sayıda hücrenin çeşitli şekillerde bağlanması ile oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hata tolerans etme yetenekleri son derece yüksektir. YSA, paralel yapısı nedeniyle büyük ölçekli tümdevre (Very Large Scale Integration (VLSI)) teknolojisi ile

gerçeklenebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir. YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, daha önce açıklandığı gibi bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'lar benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirmektedir.

Hedef sınıflandırma çalışmalarında kullanılabilecek olan temel yapay sinir ağı yapıları; çok katmanlı algılayıcılar, radyal temelli fonksiyon ağı, genelleştirilmiş regresyon ağı ve olasılıksal sinir ağı olup bu bölümde incelenmektedir.

2.2.2. Olasılıksal Sinir Ağları (Probabilistic Neural Network (PNN))

Olasılıksal sinir ağı, Bayes-Parzen kestiriciler olarak da bilinmektedir [63][78]. Bayes karar kuralı ve Parzen yoğunluk fonksiyonlarından yararlanılan olasılıksal ağ yapısı ile sınıflandırma işlemi gerçekleştirilmektedir. Bir PNN ağı, her biri farklı bir sınıf için Parzen PDF (probability density function) kestiricisi görevi yapan çok sayıda alt ağdan oluşmaktadır.

Dört katmandan oluşan PNN ağlarının ilk katmanını sınıflandırılacak öznitelik vektörleri oluşturmaktadır. İkinci ve üçüncü PNN katmanlarında, eğitim verisi setindeki verilerin her biri kullanılarak oluşturulan Parzen olasılık yoğunluk fonksiyonunun değeri hesaplanmaktadır. Denklem (2.9) içerisinde, m ile giriş vektörünün boyutu, σ ile yumuşatma parametresi, N ve x_i ile ise dikkate alınan sınıfa ait eğitim veri vektörü sayısı ve eğitim setindeki her bir öznitelik vektörü ifade edilmektedir. Her bir sınıf için oluşturulan Parzen PDF ifadesi;

$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m N} \sum_{i=1}^N \exp \left[\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (2.9)$$

biçimindedir. Eşitlikte görüldüğü gibi, PNN ağ yapısında, ikinci katmanda bir sınıfın tüm eğitim verileri çekirdek fonksiyonda dikkate alınarak oluşturulan üstel baz fonksiyonları üçüncü katmanda ağırlıklı olarak toplanmakta ve böylece test edilecek herhangi bir öznitelik vektörü için ilgili sınıfa olan benzerliği hesaplamaya yarayacak

Parzen PDF fonksiyonuna ulařılmaktadır. PNN ađının son katmanında ise, test verileri iin hesaplanan her bir sınıfa ait Parzen PDF deđeri, elde olması durumunda nsel olasılık deđeri ile birlikte deđerlendirilerek test vektr iin atama iřlemi yapılmaktadır. Bayes karar kuralı dikkate alınarak, sınıflandırma kuralı;

$$x \in C_i \leftrightarrow P_i F_i(x) > P_j F_j(x), \forall i \neq j \quad (2.10)$$

biiminde tanımlanmaktadır. (2.10) ifadesinde, C_i i. sınıfı, P ise sınıflara iliřkin nsel olasılık deđerini gstermektedir.

Tez alıřması kapsamında uygulanan PNN yntemine iliřkin dinamik parametreler Tablo 2.2 tablosunda sergilenmektedir. PNN algoritması zelinde gerekleřtirilen alıřmanın tekrarlanabilirliđi aısından kritik parametreler katman sayısı ve radyal temel fonksiyon dađılımıdır. İlgili parametrelere ait en iyi sonucu veren ve kullanılan deđer bilgisi tabloda sunulmuřtur.


Tablo 2.2. PNN sınıflandırma algoritması iin kullanılan parametreler

	Parametre	Kullanılan Deđer	Aıklama
1	Number Of Layers	2	Katman Sayısı
2	Pnn Spread	0,1	Radyal temel fonksiyon dađılımı

2.2.3. Konvolsyonel Sinir Ađları (CNN)

Derin đrenme (Deep Learning) [64][41], derin mimariye dayanan, gizli katmanların sayısı arttırılmıř ve her katmanda probleme dair bir zneliđin (feature) đrenildiđi yapay sinir ađlarından oluřan yntemler btndr. Bu mimaride her katmanda probleme ait bir znelik đrenilir ve bu đrenilen nitelik bir st katmana bir girdi oluřturur. Bylelikle en alt katmandan en st katmana dođru en basitten en karmařık niteliđin đrenildiđi bir yapı kurulmuř olur. Derin đrenme son yılların en nemli konuları arasındadır. Grnt iřleme, ses tanıma ve dođal dil iřleme gibi alanlarda kendine yer bulmuřtur. Google [65], Facebook [66][43], Baidu [67], Microsoft [64] gibi firmalar bu konu zerinde alıřmalar yrtmektedir. Elde edilen menzil profillerinden gemi hedeflerinin sınıflandırılması alıřmalarında derin đrenme yntemlerinden Konvolsyonel Sinir Ađları (Convolutional Neural Networks -

CNN) yöntemi kullanılmıştır. CNN ağına ilişkin temsili bir gösterim Şekil 2.21 şeklinde gösterilmektedir.



Şekil 2.21. CNN ağı bileşenlerinin temsili

Şekil incelendiğinde, bir CNN ağına birbiri ardına çok sayıda katman olduğu görülmektedir. İlk katmanın giriş, son katmanın ise çıkış katmanı olduğu bir CNN ağına ortadaki katmanlar temel olarak “konvolüsyon”, “birleştirme”, “ReLU (Rectifier Linear Unit)” ve “tam bağlı” katmanlarıdır. Konvolüsyon katmanlarında, giriş işaretleri belirli boyutlarda konvolüsyon filtreleri ile filtrelenerek öznetelik haritaları oluşturulmaktadır. Bu öznetelik haritaları, giriş işaretlerine ilişkin farklı seviyelerde özellik öğrenimi işlemi gerçekleştirdiği için CNN tabanlı sınıflandırıcı yapılarında sınıflandırma öncesinde ilave bir öznetelik çıkartımı aşaması uygulanmamaktadır. Kullanılacak konvolüsyon filtresindeki sayı ve çeşitlilik, her bir katmanda öğrenilecek öznetelik çeşitliliği ile doğrudan ilişkili olmaktadır. Birleştirme katmanlarında ise, ortalama alma veya maksimumu alma gibi işlemler uygulanarak öznetelik haritalarında veri boyutu azaltımı sağlanmaktadır. Örnek vermek gerekirse, Şekil 2.7 şeklinde de uygulanmış olduğu gibi 2x2 boyutlu bir pencere kullanılarak yapılan birleştirme işleminde, öznetelik haritasındaki her dört örnek bir adet örnek ile temsil edilerek öznetelik haritasındaki veri sayısı dörtte birine indirilebilmiştir. ReLU katmanında $y = \max(x, 0)$ gibi doğrusal olmayan fonksiyonlar kullanılarak katmanlar arası verilerin doğrusal olmayan dönüşümü mümkün kılınmaktadır. Sınıflara ilişkin veriler arasındaki doğrusal olmayabilen ayırım yüzeyleri, ReLU gibi işlemler ile daha uygun bir biçimde tasarlanabilmektedir. Tam bağlı katmanda ise, ayrı kollarından ilerleyebilen tüm öznetelik haritaları ile çıkış katmanı arasında bağlantı kurulmaktadır. CNN ağlarının eğitimi sırasında, konvolüsyon katmanlarına ilişkin konvolüsyon filtreleri ve tam bağlı katmana ilişkin katsayılar belirli bir kural gözetilerek ilklendirilmektedir. Bununla birlikte, eğitim için ayrılmış tüm giriş veri vektörleri sisteme uygulanarak ve sınıf etiketleri dikkate alınarak hata maliyet

fonksiyonu hesaplaması yapılmaktadır. Hata maliyet fonksiyonunun minimizasyonu prensibi dikkate alınarak geriye doğru propagasyon (back propagation) yöntemi ile konvolüsyon filtre katsayıları ve tam bağlı katsayılar her bir giriş verisi kullanımı sonrasında güncellenmektedir. CNN ağları, geleneksel YSA'lara göre hafıza gereksinimi ve işlem hızı açısından oldukça üstün olmaktadır. Tam bağlı katmanlar yerine konvolüsyonel filtrelerin kullanılması daha az parametrenin öğrenilmesine olanak sağlamakta, bu da hem işlem hızını artırmakta, hem de çok sayıda öznetelik haritası oluşturulabilmesine ve yine çok fazla gizli katman tasarımına olanak sağlamaktadır. Tez çalışması kapsamında uygulanan CNN yöntemine ilişkin dinamik parametreler Tablo 2.3 tablosunda sergilenmektedir.


Tablo 2.3. CNN sınıflandırma algoritması için kullanılan parametre kümesi

	Parametre	Parametre Aralığı	Kullanılan Değer
1	NLMeans Filtreleme Esik Seviyesi	0,15-0,3	0,15
2	Katman Sayısı	5-9	7
3	Aktivasyon Fonksiyonu	relu-tanh-sigmoid	Relu
4	Batch size	32-64-128-256-512	64
5	Epoch	1-100	48

2.2.4. YOLO

YOLO nesne tanıma yöntemi ismini "You only look once" cümlesinin baş harflerinden almaktadır. YOLO 2016 itibari ile yüksek hız ve başarımlar sağlayan bir nesne tanıma yöntemi olarak tanıtılmıştır. Bu yöntemin tahmin mekanizmasının hızlı ve doğru karar verebilmesi, görüntüyü tek seferde konvolüsyonel sinir ağından geçirerek görüntüdeki tüm nesnelerin sınıfını ve nesnenin görüntü üzerindeki lokasyonunu tahmin edebilmesi esasına dayanmaktadır. Tahmin işleminin temeli, nesne tespitini tek bir regresyon problemi olarak ele almasıdır. YOLO, taradığı bölgelere bağlantı kutuları ızgara (anchor box (AB)) adı verilmektedir. Eğitimde öncelikle, ele alınan görüntü verisi $S \times S$ boyutlu ızgara yapıya dönüştürülür. Her bir ızgara içerisinde bir nesne olup olmadığı kontrol edilir. Eğer ızgarada nesne var ise ve nesnenin orta noktası bu ızgaranın içerisinde yer alıyorsa bu ızgara nesnenin tespit edilmesinden sorumlu olmaktadır. Bu şekilde YOLO her ızgarada yer alan AB'ler için denklem (2.11)' deki gibi bir değer vektörü oluşturur. Burada p_c ile, ilgili ızgara

alanında herhangi bir hedefin bulunma olasılığı, b_x , b_y , b_w ve b_h ile ise, sırasıyla ızgara alanının x ve y doğrultularındaki normalize merkez koordinatları ile birlikte ızgara alanının genişliği ve yüksekliği temsil edilmektedir. Tespit vektöründe yer alan c_1, c_2, \dots, c_n değerleri ise her bir sınıf için ızgara alanında bulunma olasılığını vermektedir.



Şekil 2.22. YOLO ızgara yapısı

$$y = [p_c, b_x, b_y, b_w, b_h, c_1, c_2, \dots, c_{12}] \quad (2.11)$$

Ayrıca b_x , b_y , b_w ve b_h parametreleri hesabı denklem (2.12)'de olduğu gibi belirlenmektedir. Denklem grubunda yer alan $XGmin$ ve $XGmax$ değerleri etiketin minimum ve maksimum x pozisyonunu, $YGmin$ ve $YGmax$ değerleri etiketin minimum ve maksimum y pozisyonunu, IW etiketin genişliğini, IH etiketin yüksekliğini, WG ve HG değerleri ise görüntünün genişliğini ve yüksekliğini ifade etmektedir.

$$b_x = XGmin + XGmax / 2 * (1 / WG)$$

$$b_y = YGmin + YGmax / 2 * (1 / HG)$$

(2.12)

$$b_w = IW / WG$$

$$b_h = IH / HG$$

Eğitim sırasında etiketlenen verilerin genişlik ve yükseklik değerleri k -means öbekleme algoritmasına verilerek k adet farklı ızgara belirlenmektedir. Bu algoritma başlangıçta rastgele k adet öbek genişlik ve yükseklik değeri belirlemekte, sonrasında

etiketlenen verilerin komşuluk prensibine göre bu öbeklere ataması yapılmaktadır. Tüm atamalar sonrasında öbek merkezleri tekrar hesaplanmakta ve tekrar komşuluk hesaplaması yapılmaktadır. Bu durum tekrar edilerek optimizasyon ile k adet ızgara belirlenmektedir. Etiketlenen veriler ızgara hücrelerine Şekil 2.23 şeklindeki gibi atanırlar. Şekilde çevreleyen kutu (bounding box (BB)) kısmında görüldüğü gibi her BB'de seçilmiş AB'ler için bir değer vektörü oluşturularak, sırasıyla girdi görüntüsündeki her BB için tüm AB alanları doldurulur. Şekil 2.23 şekliinden de görüldüğü gibi $BB8$ haricindeki diğer tüm AB'ler boş olacaktır.

$$\begin{array}{c}
 \left[\begin{array}{c} p_c \\ b_x \\ b_w \\ b_h \\ b_w \\ c1 \\ c2 \\ c3 \\ p_c \\ b_x \\ b_w \\ b_h \\ b_w \\ c1 \\ c2 \\ c3 \end{array} \right] \\
 \left. \begin{array}{l} \text{(AB1)} \\ \\ \\ \text{AB2} \end{array} \right\} \\
 y = \\
 \left. \begin{array}{l} \text{BB} \end{array} \right\} \\
 = \\
 \left[\begin{array}{c} 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \end{array} \right] \left[\begin{array}{c} 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \end{array} \right] \dots \left[\begin{array}{c} 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ \mathbf{1} \\ b_x \\ b_w \\ b_h \\ b_w \\ 0 \\ 1 \\ 0 \end{array} \right] \left[\begin{array}{c} 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \\ 0 \\ ? \\ ? \\ ? \\ ? \\ ? \\ ? \end{array} \right] \\
 \left. \begin{array}{l} \text{BB1} \quad \text{BB2} \\ \dots \\ \text{BB8} \quad \text{BB9} \end{array} \right\}
 \end{array}$$

Şekil 2.23. Etiketlenen verilerin ızgara hücrelerine atanması

Şekil 2.23 şeklinde $BB8$ 'de belirlenen AB'lerde nesne olduğundan $BB8$ vektörü p_c alanına 1 yazılacaktır. YOLO tahmin yöntemi tariflenmesi için tahmin matrisi Şekil 2.24 şeklinde verilmiştir. Sınıflandırma tahmini için belli adımların izlenmesi gerekmektedir. Öncelikli olarak matrisin yeşil ile belirtilmiş alanında yer alan her AB'nin p_c alanı kontrol edilerek nesne olup olmadığı belirlenir.

İçerisinde nesne olan AB'lerde bulunan her bir sınıf için işlemler ayrı ayrı gerçekleştirilir. Koşullu olasılığı önceden belirlenmiş olan eşik seviyesi 0.5 değerinin altında olan ilgili sınıf değeri sıfıra eşitlenir. Kalan AB'ler olasılık değerine göre büyükten küçüğe doğru sıralanır. Büyük olasılık değerli AB için IoU hesaplanarak eşik seviyesinden büyük olan AB olasılık değerleri aynı hedef bölgesini gösterdikleri gerekçesi ile en büyük AB değeri tutularak diğer AB değerleri sıfıra eşitlenir. Bu şekilde ele alınan AB ile işlem bitince diğer AB'ler için işlemlere aynı şekilde devam

edilir. AB içerisinde yer alan en yüksek olasılığa sahip sınıfa atama yapılarak sınıflandırma gerçekleştirilmiş olur.

$$y = \begin{bmatrix} p_c & p_c & p_c & p_c & \dots & p_c & p_c \\ b_x & b_x & b_x & b_x & \dots & b_x & b_x \\ b_y & b_y & b_y & b_y & \dots & b_y & b_y \\ b_w & b_w & b_w & b_w & \dots & b_w & b_w \\ b_h & b_h & b_h & b_h & \dots & b_h & b_h \\ c_1 & c_1 & c_1 & c_1 & \dots & c_1 & c_1 \\ c_2 & c_2 & c_2 & c_2 & \dots & c_2 & c_2 \\ c_3 & c_3 & c_3 & c_3 & \dots & c_3 & c_3 \end{bmatrix}$$

$\underbrace{\hspace{1.5cm}}_{AB1}$
 $\underbrace{\hspace{1.5cm}}_{AB2}$
 $\underbrace{\hspace{1.5cm}}_{AB3}$
 $\underbrace{\hspace{1.5cm}}_{AB4}$
 \dots
 $\underbrace{\hspace{1.5cm}}_{AB17}$
 $\underbrace{\hspace{1.5cm}}_{AB18}$

Şekil 2.24. YOLO tahmin yöntemi tanımı

Tez çalışması kapsamında uygulanan YOLO yöntemine ilişkin dinamik parametreler Tablo 2.4 tablosunda sergilenmektedir.

Tablo 2.4. YOLO kapsamında kullanılan parametrelerin değerleri

	Parametre	Kullanılan Değer	Açıklama
1	Num	5	Her BB için AB sayısı
2	Filters	85	Konvolüsyon Çıktı Katmanı
3	Subdivision	8	Adım Sayısı
4	Batch	64	Tek seferde işlenecek görüntü sayısı
5	Max_Batches	60000	Maksimum görüntü sayısı

2.3. Servis Odaklı Mimari İle Otomatik Sınıflandırma

Servis tabanlı mimari (Service Oriented Architecture (SOA)), servis olarak adlandırılan özerk yapıdaki bileşenlere dayalı dağıtık sistemlerin geliştirilmesi için farklı ağlardan erişilebilen dağıtılmış platformlarda çalıştırmayı mümkün kılan yazılım uygulamalarını dinamik olarak bağlamalarını ve iletişim kurmalarını sağlayan yöntemleri ve teknolojileri kullanan bir mimari stildir. SOA, servisleri iyi tanımlanmış bileşenlere ayırarak bir ağ üzerinden hizmet olarak erişilebilir hale getirir. SOA uygulamaları uygulama programlama arayüzü (Application Programming Interface (API))'ler ile çalışacak şekilde dizayn edilerek uygulamaların kolay bir şekilde entegrasyonu ve uygulamalara işlevsellik sağlanmış olur. Bu sayede

daha zengin ve daha gelişmiş uygulamalar ve bilgi sistemleri geliştirmek ve entegre etmek mümkün olmaktadır.

Servis, tutarlı bağlam çerçevesinde farklı işlevsel özellikler kümesini içeren, üreten ve tüketen taraflar arasında paylaşım aracı olarak görev yapan üst düzey bir iş konseptini kapsayan bir yazılım bileşenidir. Bu bileşenlerin en önemli özelliği ise diğer yazılım bileşenleri ile kolaylıkla bir araya gelebiliyor olmasıdır. Söz konusu birleştirme yani entegrasyon fikrinin arkasında ise servis odağı sunulacak teknoloji ile iş dünyasındaki kullanıcıların zor yazılımlar kullanmaksızın yazılım bileşenlerinin kullanılmasını amaçlar. Yazılım kodlarının küme içerisinde birleştirilebilecek ve sistemin farklı noktalarında tekrar kullanılabilir şekilde ayrılabilmesi SOA'nın temelini oluşturur. Servisler aşağıdaki özelliklere sahiptir.

Durumsuzluk (Statelessness) : SOA servisleri en son işlenen işlemin ne olduğunu ve gelecek işlemin ne olduğunu önemsemez. Servisler diğer servislerin içeriğine veya durumuna bağlı değildir, sadece servisler için diğer servislerin işlevselliği önemlidir. Web sayfaları buna çok güzel bir örnektir, burada bir kullanıcıdan bir web sayfası veya URL için gelen her istek, istenen sayfaların sunulmasını sağlar, ancak web sunucusu daha sonra isteği hatırlamaz. Her istek veya iletişim, öncesinde veya onu takip eden taleplerle ayrı ve ilgisizdir. Durumsuzluk, servisin çalışırlığını ve genişleyebilirliği etkileyebileceğinden servislerin mümkün olduğu kadar durumsuz tasarlanması gereklidir.

Keşfedilebilirlik (Discoverable) : Bir servis potansiyel tüketiciler tarafından keşfedilebilir olmalıdır. Sonuçta bir servisin var olduğu bilinmiyorsa hiç kullanılamayacaktır. Servisler, servis tüketicileri tarafından keşfedildikleri ve çağrıldıklarından SOA hizmet dizininde servis sağlayıcılar tarafından yayınlanır veya açıklanır.

Standartlara Dayalılık (Industry Standards-Based) : Servisler mevcutta tanımlanmış olan standartlara uygun şekilde oluşturulmalıdır. Bu sayede uygulamalar birbiriyle daha rahat çalışabilmektedir. **Öz-Açıklamalılık (Self-Described) :** SOA servis arayüzü servisi tarif eder, sergiler ve giriş noktası sağlar. Arayüz, tüketicinin teknik uygulama detaylarını anlamasına veya görmesine gerek duymadan bir servisi keşfetmesi ve ona bağlanması için gerekli tüm bilgileri içerir.

Birleştirilebilirlik (Combinable) : SOA servislerinin her biri bir bileşendir. Bunlar, diğer servislerden oluşabilir ve daha sonra, yeni iş çözümleri oluşturmak için diğer servisler ile birlikte kullanılabilirler.

Tekrar kullanılabilirlik (Reusability) : SOA'nın temel amaçlarından birisi hizmetleri tekrar tekrar kullanarak kurum kaynaklarını en verimli şekilde değerlendirebilmektir. Bunun için tasarlanan servisler tekrar kullanıma uygun olmalıdırlar. Servisleri optimum büyüklükteki parçalar olarak tanımlamak SOA için önemli bir kriterdir.

Gevşek Bağımlılık (Loosely Coupled) : Eğer bir bileşenin kendi görevlerini yerine getirmesi için bir diğer bileşenden faydalanması gerekiyor ise, bu ilişki bir bağlanım (coupling) olarak nitelendirilir. Sıkı bağımlı yazılım sistemleri, yazılım yapısı içindeki modüllerin bilinmeyen gereksinimleri nedeniyle yapılandırmak zordur. Gevşek bağlı modüller ise esnektir ve iyi tanımlanmış bağımlılıkları vardır.

Bağımsız çalışabilmek (Autonomous) : Bir servis başka bir hizmetten bağımsız ve etkilenmeden çalışabilmelidir. Yani bir hizmeti kullanabilmek için başka bir hizmetin orada hazır olmasına gerek olmamalıdır.

İlkelere Göre Yönetilirlik (Governed by policy) : Servisler sözleşmeler ile oluşturulurlar. Servisler ve servis etki alanı arasındaki ilişkiler, ilkeler ve servis düzeyi anlaşmaları (SLA'lar) tarafından süreç tutarlılığını ve karmaşıklığı azaltarak yönetilir.

Birlikte Çalışabilirlik (Interoperability) : Servislerde konum, dil ve protokol bağımlılığı bulunmamaktadır. Servisler herhangi bir platformdan, herhangi bir konumdan ve herhangi bir dille yazılmış uygulamadan çağrılabilir. Servislerin yukarıdaki özniteliklere ek olarak aşağıdaki gibi karakteristik özellikleri vardır.

İri Tanelilik (Coarse Grained) : Taneciklilik kavramı, yazılım sistemindeki arabirimlerin uygulanma şekli ile ilgilidir. Eğer arayüz, komple iş mantığı için gerekli olan tüm işlevleri destekliyorsa, bu kaba taneli bir arayüzdür. Buna karşılık, arayüz belirli işlevselliğin yalnızca bir bölümünü uygularsa, bu arayüz ince taneli olarak kabul edilir. SOA farklı parçacık düzeylerine sahip iri taneli arayüz tasarımı

desteklemektedir. Servisi oluşturan nesnelere ince taneli olabilir, ancak bu nesnelere servisin fiziksel yapısında saklanır.

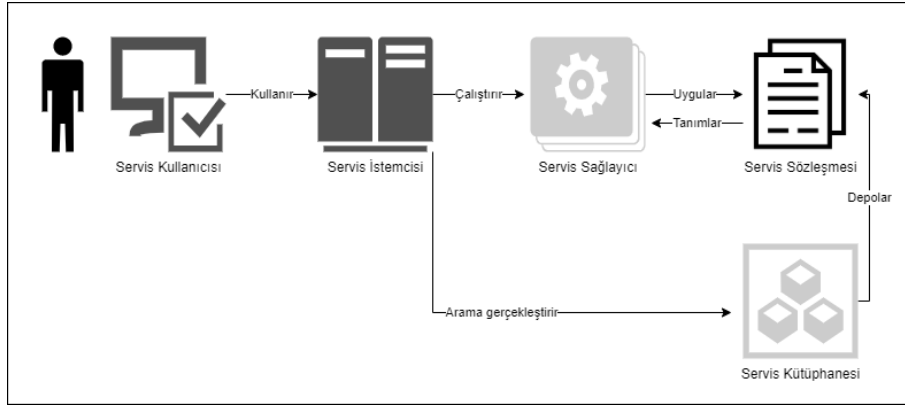
Zaman Uyumsuz Olmak (Asynchronous) : Bir SOA servisi için zaman uyumsuz iletişim gerekli değildir, ancak zaman uyumsuz davranış ve ileti gönderme teknikleri aracılığıyla sistem ölçeklenebilirliğini artırılır. Servislerin dağıtılmış niteliğinden dolayı tahmin edilemeyen ağ gecikmesi ve yüksek iletişim maliyetleri SOA ortamında yanıt sürelerini yavaşlatabilir. Zaman uyumsuz davranış ve mesajlaşma, bir servisin bir servis isteği yayınlamasına ve ardından servis sağlayıcı bir yanıt gönderene kadar işleme devam etmesine izin verir. Bu sayede farklı zamanlarda gerçekleştirilen isteklere yanıt vermek için bir diğer işin bitirilmesini beklemek zorunda olmamaktadır.

2.3.1. SOA fonksiyonel bileşenleri

Servis Odaklı Mimari üç ana fonksiyonun arasındaki etkileşim modelini tanımlayan mimari bir stildir.

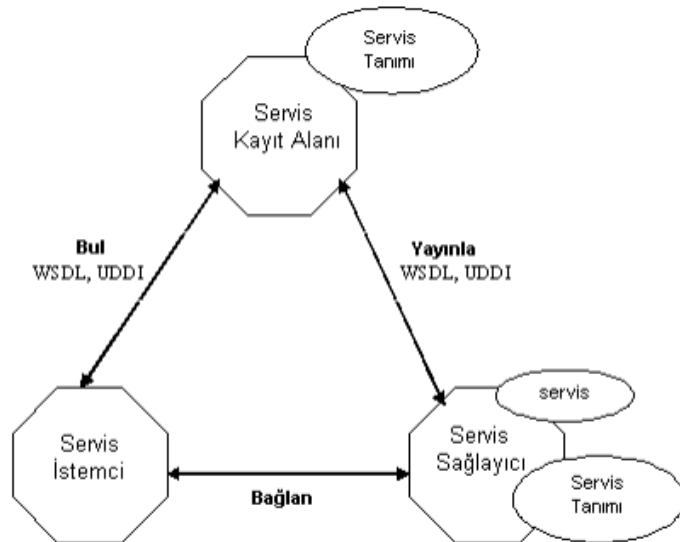
Bu etkileşimi açıklayan meta-model Şekil 2.8 şeklinde gösterilmiştir. SOA kavramsal modelinde 6 adet bileşen bulunmaktadır. Bunlar; Servis Tüketicisi (Service Consumer), Servis Sağlayıcısı (Service Provider), Servis Kayıt Defteri (Service Registry), Servis Sözleşmesi (Service Contract), Servis Vekili (Service Proxy), Servis Kiralama (Service Lease) şeklindedir. SOA kavramsal modelinde 6 adet bileşen bulunmaktadır. Bunlar; Servis Tüketicisi (Service Consumer), Servis Sağlayıcısı (Service Provider), Servis Kayıt Defteri (Service Registry), Servis Sözleşmesi (Service Contract), Servis Vekili (Service Proxy), Servis Kiralama (Service Lease) şeklindedir. Servis tüketicisi, SOA'da, gerekli bir fonksiyonu yürütmek için bir servis arayan varlıktır [45]. Tüketici, servise ihtiyaç duyan bir uygulama, başka bir servis veya başka bir yazılım modülü türü olabilir. Servisin konumu kayıt defterine bakılarak keşfedilir veya biliniyorsa, tüketici doğrudan servis sağlayıcısı ile etkileşim kurabilir. Servis sağlayıcısı, tüketicilerin taleplerini kabul eden ve yürüten ağa adreslenebilir bileşendir. Servisin kesin tanımını ve servisin uygulanmasını sağlar. Servis sağlayıcı, hizmet tüketicisinin gereksinimlerini karşılayan bir bileşen veya başka bir yazılım sistemi olabilir. Servis kayıt defteri ağ üzerinden erişilebilen ve mevcut hizmetleri içeren bir dizindir. Ana işlevi, servis

sağlayıcısından gelen servis açıklamalarını saklamak, yayınlamak ve bu açıklamaları ilgilenen servis tüketicilerine sunmaktır. Servis sözleşmesi, servis tüketici ve sağlayıcı arasındaki etkileşimi açıklayan tanımdır.



Şekil 2.25. SOA fonksiyonel bileşenleri

İstek-yanıt mesajı formatı, servisin hangi koşullarda yürütüleceği ve servisin kalite gereksinimleri hakkında bilgileri içerir. Servis vekili, tüketicinin kendi dilinde yazılı bir API sağlayarak servis sağlayıcı ve servis tüketici arasındaki etkileşime yardımcı olur. Performansı artırabilir ve önbellekleme olanakları sağlar. SOA da opsiyonel bir bileşendir. Servis kiralama, bir servis sözleşmesinin geçerli olduğu süreyi belirtir. Kayıt defteri ile yönetilir ve yürütmenin iyi tanımlanmış zaman dilimlerini servislere bağlanmasını kararlaştırır. Servis kira kullanımı, servis sağlayıcı ve tüketici arasındaki gevşek bağlantıyı ve servis için durum bilgisinin korunmasını destekler.



Şekil 2.26. Web servisi kullanımı

Servis tüketicisi, servis sağlayıcısına istek mesajı gönderir. Servis sağlayıcısı da servis tüketicisine cevap mesajı gönderir. İstek ve müteakip yanıt bağlantıları hem servis tüketici hem de servis sağlayıcı tarafından anlaşılabilir mesajlaşma protokollerine uygun bir şekilde tanımlanır.

2.3.2. Web servisleri

Web Servisleri dağıtılmış bir ortamda herhangi bir sayıda uygulama veya uygulama bileşenleri birbirleriyle sorunsuz bir şekilde birlikte çalışabilen uygulamalardır. Bundan dolayı uygulama geliştirmede giderek daha fazla kullanılır hale gelmiştir. Web servislerinin en önemli faydası, uygulamaların herhangi bir dille yazılabilir ve herhangi bir platformda çalışabilir olmasıdır. Web Servisleri standart İnternet teknolojileri kullanılarak gerçekleştirilir.

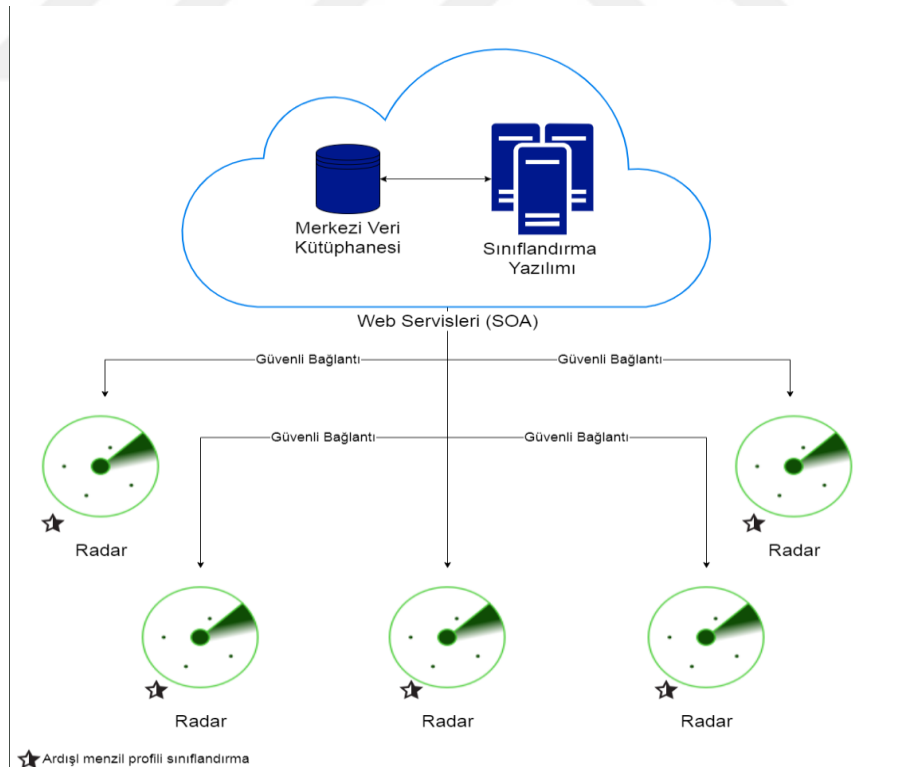
Web Servisleri, sistemin birlikte çalışabilirliği için hipermetin transfer protokolü (Hypertext Transfer Protocol (HTTP)), uzatılabilir biçimleme dili (Extensible Markup Language (XML)), SOAP ve evrensel betimleme, buluş ve entegrasyon (Universal Description, Discovery and Integration. (UDDI)) gibi platforma bağlı olmayan standartları kullanır ve var olan hemen hemen her teknoloji satıcısı tarafından desteklenir. Bu durum Web Servislerini platform bağımsız yapar. Platform bağımsızlığı dünyayı saran ağ (World Wide Web (WWW)) alanında yoğunlukla kullanılır. Web siteleri kullanıcının web tarayıcısından bağımsız olarak geliştirilirler. Web tarayıcısı, sunucu sitedeki dillerin ve platformların bilgisine ihtiyaç duymaz. Aynı prensip web servisleri için de geçerlidir. Kullanıcı metot çağrılarında kullanacağı servisin sadece alan adı (Uniform Resource Locator (URL)) adresini ve veri tipini bilmesi gereklidir. Kullanıcı web servislerini, Java'da oluşturulup oluşturulmadığını, Linux'ta çalışmakta olup olmadığını veya Windows'ta çalışan bir .NET Web servisi olup olmadığını bilmeden kullanabilir. Uygulamaların ayrıntıları kullanıcıdan gizlenir.

Web servislerini mimarisi üç rolün etkileşimi üzerine kurulmuştur. Servis sağlayıcı, servis kaydı ve servis istemcisi rollerini içerir. Bu roller yayınlama, bulma ve bağlama operasyonlarını kapsar. Tipik bir senaryoda servis sağlayıcı network ulaşımına açık bir yazılım modülüne ev sahipliği eder. Servis sağlayıcı servis tanımını belli bir web servis için tanımlar ve bunu bir servis kayıt alanına veya servis

istemcisine yayımlar. Servis istemci bir arama operasyonu ile servis tanımını lokal olarak veya servis kayıt alanından çeker. Servis tanımını servis sağlayıcıya bağlanmak, web servis uygulamasını çalıştırmak veya etkileşmek için kullanır. Servis sağlayıcı ve servis istemci rolleri mantıksal yapılar ve bir servis ilişkisinin karakteristiklerini de miras edebilir. Web servislerinin karma platformlar arasındaki birlikte çalışabilirlik, her yerde bulunan ağ teknolojileri üzerinde çağırılabilirlik gibi birçok belirgin yararı vardır. Web servisleri birlikte çalışabilmek için SOA'nın paylaşılan bir dizi organizasyon prensiplerini kullanır ve web servisleri içerisinde belirlenen rolleri uygulamaktadır.

2.3.3. SOA ile merkezi sınıflandırma mimarisi

Servis odaklı mimari uzaktan erişim ile servis hizmeti sağlamayı amaçlamaktadır. Tez kapsamında geliştirilen deniz hedefi sınıflandırma altyapısının bir çok kara konuşlu radar istasyonunda kullanılacağı düşünüldüğünde merkezi sınıflandırma hizmetinin önemi artmaktadır.



Şekil 2.27. Merkezi hedef sınıflandırma kütüphanesi mimarisi

Her radar istasyonunun gözlemlediği hedef tipleri ve ilgi alanı farklı olacağından SOA'nın kurulacağı merkezde bulunacak hedef kütüphanesi sayesinde daha önceden

karşılaşılmaş hedef tipleri için de sorgulama imkanı saęlayacaktır. Merkezi sınıflandırma kütüphanesi bir çok noktadan ölçümsel veri ile beslenecektir. SOA'ya entegrasyon kapsamında web servisler oluşturularak sınıflandırma hizmetini sunmak için mimari tasarım gerçekleştirilmiştir. Web servislerin kullanacağı verilerin yönetimi için veri kütüphanesi ihtiyacı bulunmaktadır. Tüm radar sistemlerine ortak veri kütüphanesinden hizmet verecek olan servis kütüphanesi ihtiyacı tasarlanmıştır. Geliştirilecek olan web servisleri ile SOA standartlarına uygun olarak haberleşme imkanı incelenmiştir. Web servisler ile onu kullanacak kullanıcı dilden bağımsız olarak iletişim kurduklarından dolayı herhangi bir programlama dilinde geliştirme yapılabilmektedir.

Sınıflandırma algoritmalarında kullanılacak olan verilerin boyutu ve tipi sınıflandırıcıya göre deęişiklik göstermektedir. Algoritmalara uygun olarak web servislerin yapısı, sayısı, kullanılacak metotlar ve veri tipi/tiplerinin belirlenmesi gerekmektedir. Bu tez kapsamında kullanılan sınıflandırma algoritmalarının merkezi olarak inşasına yönelik kavramsal mimari tasarımı Şekil 2.27 şeklinde sergilenmektedir.

Ayrıca, tez kapsamında önerilen ardışıl menzil profili sınıflandırma metodunun kümülatif olarak menzil profili sınıflandırma sonuçlarını kullanacağı merkezi sınıflandırma mimarisinin hedeflere ait takip numarası özelinde işlem yapması gerekmektedir. Farklı fiziksel lokasyonlarda bulunan sistemlerin elde ettikleri verilerin tasnifi sırasında ait olduęu hedeflere ait takip numaraları ve radar numaraları birleştirilerek eşsiz bir kimlik numarası elde edilmesi sağlanacaktır.

Merkezi sınıflandırma mimarisi kullanılarak;


- Sınıflandırma sorgulamasını yapan radar istasyonunun karşılaşmamış olabileceęi hedef hakkında da bilgi sahibi olması sağlanacaktır.
- Birden fazla radar istasyonunda karşılaşılan hedef tiplerine ait sürekli veri beslemesi sayesinde büyük bir veri kütüphanesine sahip olunacaktır.
- SOA tarafından sağlanan hizmetlere farklı dillerde ve farklı konumlarda istek gönderilebilecektir.
- Sınıflandırma algoritmaları ve/veya veri kütüphanesinde yapılması muhtemel güncellemelerin tek bir noktada yapılacak olması bakım maliyetlerini düşürecektir.

- Sınıflandırma algoritmaları ve/veya veri kütüphanesinde yapılması muhtemel güncellemeler sınıflandırma isteğinde bulunacak olan tüm noktalarda aynı zamanda gözlemlenebilecektir.
- Geliştirme dilinden bağımsız olarak sağlanacak olan hizmetler erişim protokollerini uygulayan tüm noktalardan erişilebilir olmakla birlikte taşınabilir olması sağlanmış olacaktır.
- Elde edilen verilerin merkezi kural tabanlı ön işlemeden geçirilecek olması sayesinde standart veri formatı ve içeriği belirleme imkanı sağlayacaktır.



3. ARDIŞIL MENZİL PROFİLİ FÜZYON YÖNTEMİ (AMPF)

Menzil profil verisinin içeriği hedefin tipine, büyüklüğüne, oryantasyonuna, yansıtma karakterine bağlı olarak ve ortamın koşullarına göre değişmektedir. Şekil 3.1 şeklinden de görüleceği üzere her bir menzil profili alındığı ana özel ve özgün karakteristikler sergilemektedir.



Şekil 3.1. Ardışıl menzil profillerinin temsili gösterimi

Bu tez kapsamında geliştirilen özgün ardışıl menzil profil sınıflandırma algoritması tekil menzil profili sınıflandırma sonuçları üzerinden çalıştırılmaktadır. Bu tez kapsamında geçiş matrisi üzerine inşa edilmiş bir füzyon algoritması geliştirilmiştir. Veri kütüphanesindeki ardışıl menzil profillerinin sınıflandırma sonuçları üzerinde son işlem gerçekleştirilmektedir. Geçiş matrisi adında bir olasılık matrisi kullanılmaktadır. Geçiş matrisi, aşağıdaki matriste T ile gösterilen, (i,j) index çiftleri için i 'inci durumdan j 'inci duruma geçiş olasılığını tanımlayan skotastik bir matristir. Durumların 1,2, ..., N, olarak tanımlandığı düşünüldüğünde geçiş matrisi aşağıdaki gibi olmaktadır.

Durum geçiş olasılıkları T_{ij} ile sergilenmektedir. Durum numaralarının $\forall\{i,j\} \in \{1,2, \dots, N\}$ olarak kabul edilmesi durumunda $\sum_{k=1}^N T_{ik} = 1$ eşitliğini sağlaması beklenmektedir. HRRP verisinin karakteristiği, her radar sinyalinde hedefin gerçekleştirdiği harekete bağımlı olarak değişiklik göstermektedir.


Ardışıl menzil profilleri sekiz adet veya daha fazla ardışıl menzil profili içermektedir. Ardışıl menzil profili grubunda bulunan her bir menzil profili tekil olarak ilgili sınıflandırma algoritması kullanılarak sınıflandırılmakta ve kayıt altına alınmaktadır. Bu çalışma kapsamında her bir tekil sınıflandırma sonucunun geçiş matrisinde bir duruma denk geldiği kabul edilmektedir. Geçiş matrisi olasılıkları, i 'nci durumdan j 'inci duruma geçişlerin sayısının, i 'inci durum ile başlayan geçişlerin toplam sayısına bölünmesi ile elde edilen değere eşitlenmesi ile elde edilmektedir.

$$T = \begin{bmatrix} T_{11} & T_{12} & \dots & T_{1N} \\ T_{21} & T_{22} & \dots & T_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ T_{N1} & T_{N2} & \dots & T_{NN} \end{bmatrix} \quad (3.1)$$

Geçiş matrisi ve matristeki olasılıkların grafiksel olarak gösterimi Şekil 3.2 şeklinde sergilenmektedir.

Hedef Sınıfları	HS 1	HS 2	HS 3	HS 4
HS 1	GO ₁₁	GO ₁₂	GO ₁₃	GO ₁₄
HS 2	GO ₂₁	GO ₂₂	GO ₂₃	GO ₂₄
HS 3	GO ₃₁	GO ₃₂	GO ₃₃	GO ₃₄
HS 4	GO ₄₁	GO ₄₂	GO ₄₃	GO ₄₄

HS : Hedef sınıfı
GO : Geçiş matrisi olasılığı



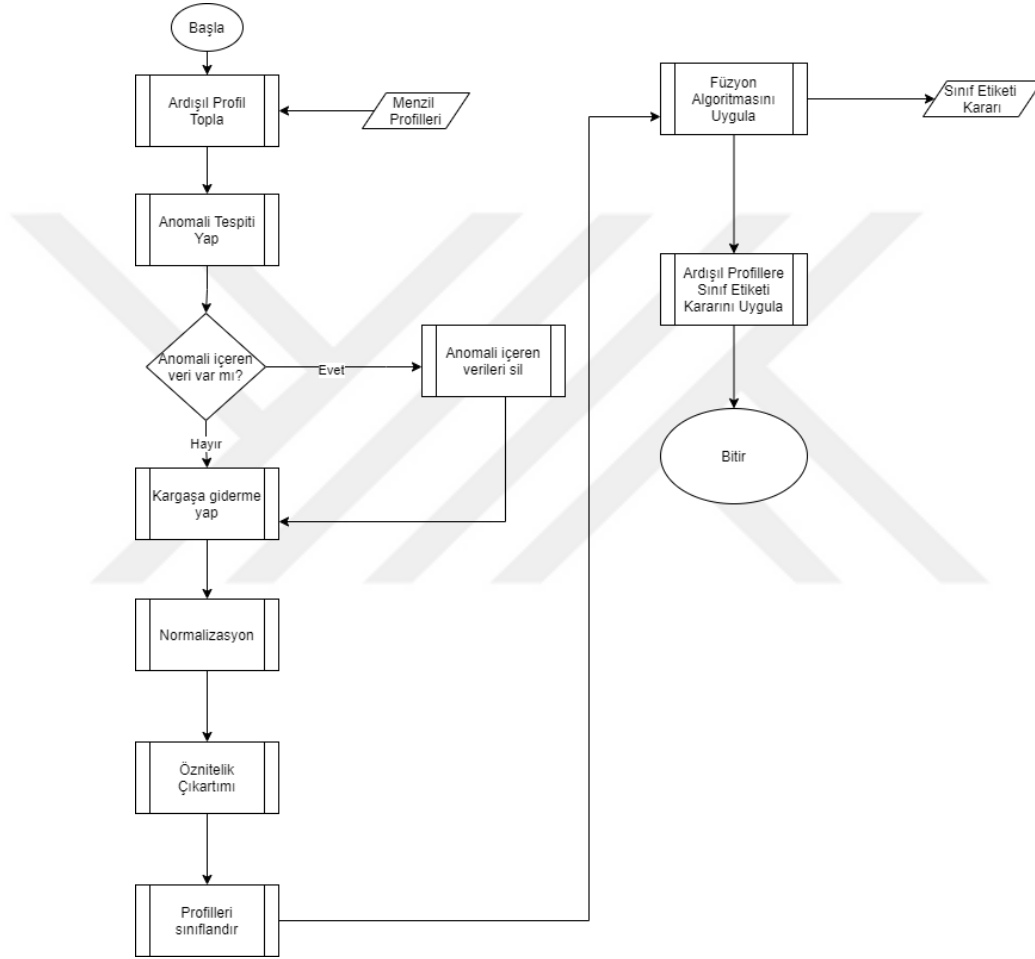
Şekil 3.2. Geçiş matrisi örneği ve durum geçiş diyagramı

Bütün T_{ij} geçiş olasılıklarının üretilmesini takiben tez kapsamında önerilen füzyon algoritması uygulanmaktadır. Kayıt altına alınan ardışıl menzil profili sınıflandırma sonuçları aşağıdaki algoritma kullanılarak son işleme tabi tutulmaktadır.

$$P_k = F_k T_{kk} \prod_{i=1, i \neq k}^N (1 - T_{ki}) \quad (3.2)$$

Burada F_k değeri, tüm sınıflandırma sonuçları içerisinde k . hedef tipinin gözlemlenme frekansını göstermektedir. N adet menzil profilinden oluşan ardışıl menzil profil alt kümesi için $N - 1$ adet geçiş matrisi durumu bulunmaktadır.

Denklem (3.1) ile belirtildiği üzere son işlem sonucunda ortaya çıkan en yüksek olasılıklı hedef tipi etiketi ardışıl menzil profili alt kümesi için karar olarak belirlenmektedir. En yüksek olasılıklı hedef tipi etiketi menzil profili alt kümesindeki tüm tekil menzil profillerinin sınıflandırma sonucu olarak atanmaktadır. Ardışıl menzil profillerinin sınıflandırılması için izlenen akış Şekil 3.3 şeklinde görselleştirilmiştir.



Şekil 3.3. Ardışıl menzil profili sınıflandırma adımları akış diyagramı

Şekilde belirtildiği üzere elde edilen ardışıl menzil profilleri ilk olarak anomali giderme, kargaşa giderme ve veri normalizasyonu adımlarından geçirilmektedir. Ön işleme sonucu elde edilen verilerin üzerinde öznitelik çıkarma çalışması gerçekleştirilmektedir. Ardışıl menzil profili veri kümesinde öznitelikleri çıkarılan her bir tekil menzil profili sınıflandırma algoritmasına tabi tutularak ardışıl sınıflandırma sonuçları elde edilmektedir. Özgün füzyon algoritması bu adımda devreye girmektedir. Ardışıl veriye ait elde edilen sınıflandırma sonuçları özgün

füzyon algoritmasına tabi tutulmaktadır. Füzyon algoritması sonucu ortaya tek bir sınıf etiketi çıkmaktadır. Ortaya çıkan sınıf etiketi ardışıl menzil profilleri içerisindeki her bir profile uygulanarak nihai sınıflandırma kararı oluşturulmaktadır. Ardışıl menzil profili sınıflandırma için hazırlanan sözde kod (pseudo-code) gösterimi Şekil 3.4 şeklinde gösterilmektedir.

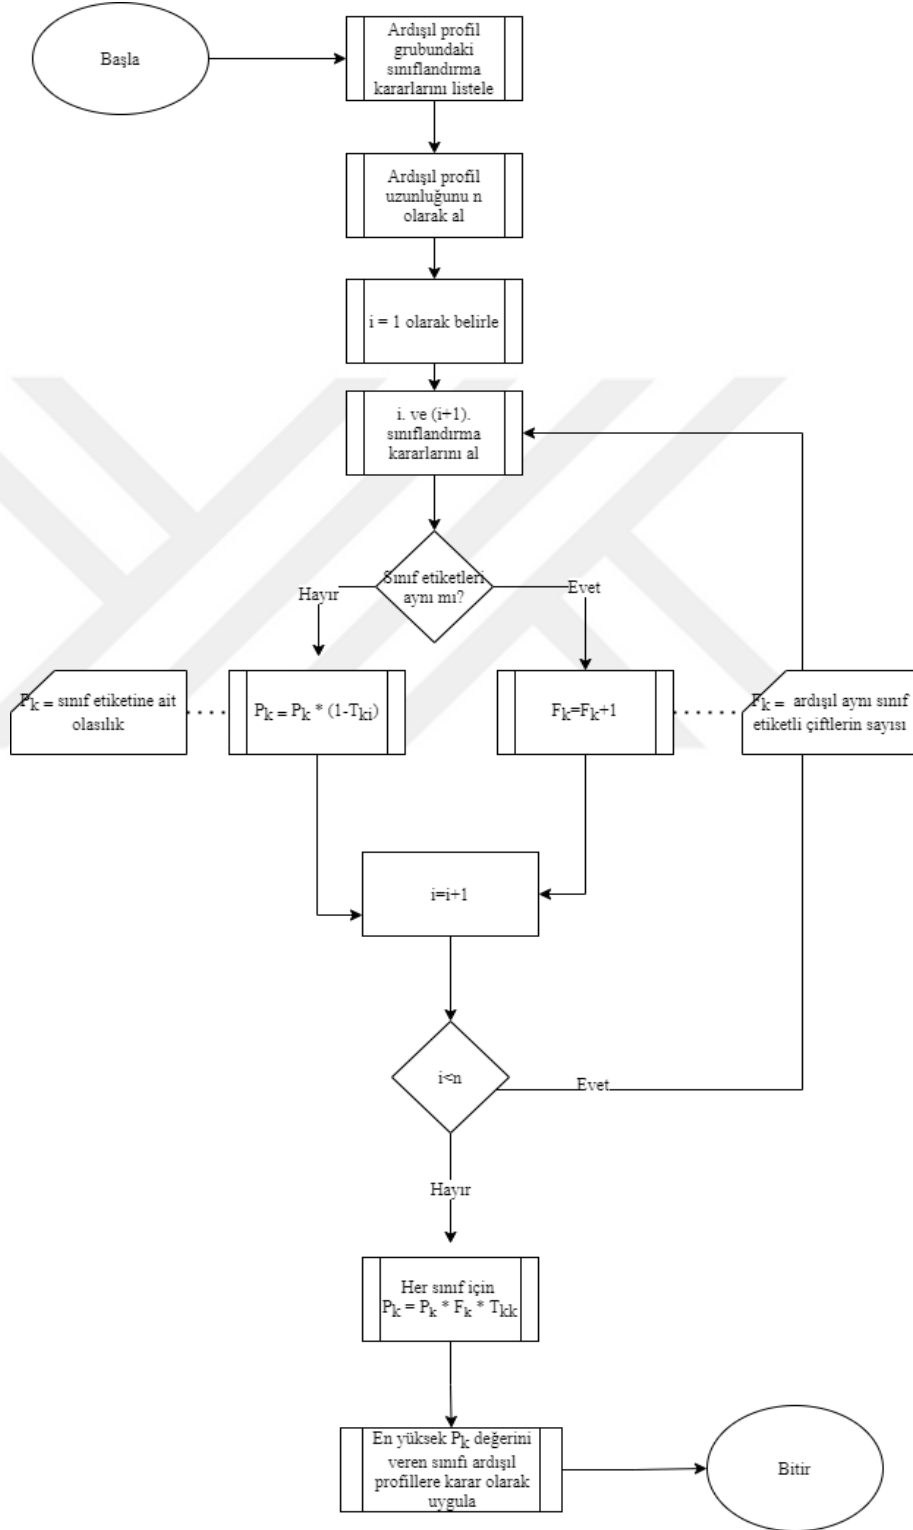
```
ADIM 1 : Başla
ADIM 2 : Ardışıl menzil profillerini al
ADIM 3 : Menzil profillerinde anomali tespiti yap
ADIM 4 : Anomali içeren verileri sil
ADIM 5 : Menzil profillerinde kargaşa giderme yap
ADIM 6 : Menzil profillerinde veri normalizasyonu yap
ADIM 7 : Menzil profillerine ait öznitelikleri hesapla (boy, genlik vb.)
ADIM 8 : Menzil profili kümesindeki her profili seçilen sınıflandırma algoritması ile tekil olarak sınıflandır (PNN, CNN, YOLO)
ADIM 9 : Ardışıl menzil profili sınıflandırma sonuçlarını vektör olarak kaydet
ADIM 10 : Ardışıl menzil profili sınıflandırma sonuçlarına füzyon algoritmasını uygula
ADIM 11 : En yüksek olasılık değerine sahip sınıf etiketini ardışıl menzil profili kümesine sınıflandırma sonucu olarak uygula
ADIM 12 : Bitir
```

Şekil 3.4. Ardışıl menzil profili sınıflandırma adımları sözde kod gösterimi

Tez kapsamında geliştirilen özgün füzyon yöntemine ait sözde kod gösterimi ardışıl menzil profillerine uygulanan son işlem adımlarını açıklamaktadır. Başlangıçta, algoritmaya girdi olarak kullanılan ardışıl menzil profillerine ait tekil sınıflandırma sonuçları içerisindeki sınıf etiketleri belirlenmektedir. İlgili sınıf etiketlerine karşılık gelen geçiş matrisi olasılıkları ve sınıf etiketlerinin karşılaşılma sıklığı kullanılarak tüm olası sınıflar için nihai sınıflandırma olasılığı değerleri elde edilmektedir. En yüksek olasılık değerini veren sınıf etiketi bilgisi ardışıl veri grubundaki her bir veriye uygulanmaktadır.

Geçiş matrisi sayesinde tespit aşamasında hedeflerin birbirine benzetilmesi ve hatalı tespit oluşturmasına engel olmak hedeflenmiştir. Ardışıl veri kümesinde tespit edilen sınıfların karşılaşılma sıklıkları ve geçiş matrisi olasılıkları kullanılarak en yüksek başarılı sınıf seçilmektedir. Özgün füzyon yöntemi olarak adlandırılan AMPF yöntemine ait akış diyagramı Şekil 3.5 şeklinde olduğu gibidir. Elde edilen ardışıl menzil profili kümeleri için oluşturulan sınıf etiketleri bir küme olarak

birleştirilmektedir. Bu veri kümesin içerisindeki etiketlerin aynı sınıfa ait olup olmadığı sorgulanması gerçekleştirilmektedir. Arka arkaya iki etiketin aynı sınıfa ait olması ve olmaması durumlarını karşılayan iki farklı olasılık hesabı yapılmaktadır.



Şekil 3.5. Özgün füzyon (AMPF) yöntemi akış diyagramı

Tüm arka arkaya ikili etiketler için hesaplanan olasılık değerlerinin karşılaştırması yapılmaktadır. Yapılan karşılaştırmada hangi sınıf etiketi baskın olasılığa sahip ise tüm ardışıl menzil profilleri bu olasılık değerine sahip sınıf etiketine atanmaktadır. Bahse konu füzyon yönteminin (AMPF) sözde kod gösterimi Şekil 3.6 şeklinde sergilenmiştir. Sözde kod içeriğinden de anlaşılacağı üzere ardışıl profillerin içerisinde bulunan sınıf etiketlerinin geçiş matrisinde bulunan durumu ile eşleniktir.

ADIM 1 : Başla
ADIM 2 : Ardışıl sınıflandırma kararlarını listele
ADIM 3 : Ardışıl ikili sınıflandırma kararlarını sırasıyla al
ADIM 4 : Her iki sınıflandırma kararı eşitse sınıf etiketi frekansını 1 arttır
ADIM 5 : Her iki sınıflandırma kararı eşit değilse $P_k = P_k * (1 - T_{ki})$ hesabı yap
ADIM 6 : Ardışıl sınıflandırma kararları tamamlandı ise $P_k = P_k * F_k * T_{kk}$ hesabı yap
ADIM 7 : En yüksek P_k değerini veren sınıf etiketini ardışıl profillere uygula
ADIM 8 : Bitir
P_k = k. sınıfa ait toplam olasılık
T_{ki} = Geçiş matrisindeki k. satır i. sütundaki olasılık değeri
F_k = k. sınıfa ait ardışıl çift karşılaşılma olasılığı

Şekil 3.6. Özgün füzyon (AMPF) yöntemi sözde kod gösterimi

4. KULLANILAN VERİ ENVANTERİ

Bu tez çalışması kapsamında iki tip veri kullanılmıştır. Birinci tür veri RASES yazılımı kullanılarak üretilen ve sentetik menzil profili olarak adlandırılan veri tipidir. Hedeflere ait 3 boyutlu tasarım dosyaları ve RASES isimli bir simülasyon yazılımı vasıtası ile elde edilen verilerdir. İkinci tür veri ise gerçek hedef ve gerçek radarlar kullanılarak ölçümsel olarak elde edilen verilerdir. Verilerin tamamı fırsat hedeflerine ait olup radar mevzii imkanları ölçüsünde fırsat hedeflerinin uzunca bir süre takip edilmesi ile elde edilmiştir. İleriki bölümlerde açıklanacak olan ve bu çalışma kapsamında önerilen metodun başarımı hem sentetik, hem de ölçümsel veriler üzerinde test edilmiştir.

4.1. Ardışıl Menzil Profillerinin Sentetik Olarak Elde Edilmesi

Radar menzil profilleri ile gemi hedefi sınıflandırma çalışmalarında hedef çeşitliliği ve bu hedeflere ait menzil profillerinin sayısı sınıflandırıcının performansı bakımından kritik önem taşımaktadır. Bu bağlamda, gürbüz, güvenilir ve yüksek performanslı sınıflandırıcı yapıları tasarlayabilmek için, eğitim veri kütüphanesinde tüm gemi hedeflerine ait mümkün olan tüm yanca ve elevasyon açılarına ilişkin menzil profillerinin bulunması gerekmektedir. Diğer taraftan, dünya genelinde farklı gemi sınıflarına ait çok sayıda ve fiziksel yapıda gemi tipi bulunmaktadır. Bu sebeple, her bir gemi sınıfına ilişkin olarak gereken tüm saha profillerini ölçümsel bir biçimde toplamak neredeyse imkânsızdır. Bu durum, gemi hedefi sınıflandırma alanında çaba sarf eden araştırmacıları, sentetik menzil profilleri ile eğitim veri tabanı oluşturmaya yöneltmektedir. Bu kapsamda, TÜBİTAK BİLGEM ürünü olan RASES aracı ile üretilen ardışıl menzil profilleri bu tez kapsamında önerilen füzyon yönteminin uygulanabilirlik gerçekleştirilmesi amacıyla kullanılmıştır.

Sentetik profil verileri ile sınıflandırıcı kütüphanesi oluşturmak için, öncelikli olarak ilgili hedef sınıflarına ilişkin bilgisayar destekli tasarım (BDT) modellerinin elde edilmesi gerekmektedir. Bununla birlikte, gerekli olması durumunda, BDT modelleri üzerinde yapılan eklemeler, düzenlemeler veya değişiklikler sonrasında uygun

elektromanyetik hesaplama araçları kullanılarak sentetik menzil profilleri elde edilmektedir. İlgili sentetik menzil profilleri kullanılarak tasarlanan sınıflandırıcı yapıları eğitilmekte ve sınıflandırıcı testleri yapılmaktadır.


Sentetik veriler ile yapılan sınıflandırıcı eğitimi prosedüründe bir takım problemler oluşabilmektedir. Öncelikle, elde edilen BDT modeller ile gerçek gemiler arasında fiziksel yapı farklılıkları bulunabilmektedir. BDT modellerde, gerçek gemi sisteminde bulunan tüm ayrıntılar modellenemeyebilmekle birlikte, gerçek gemilerin yüzeylerindeki malzeme özellikleri de (boya, kaplama vb.) BDT modellerde tam olarak karşılık bulamayabilmektedir. Bunun yanı sıra, gerçek deniz durumları veya çoklu-yol yansıması gibi fenomenler de elde edilen sentetik profiller ile ölçümsel profiller arasında farklılıklar doğmasına sebep olabilmektedir. Sentetik veriler ile yapılan sınıflandırıcı eğitimi kapsamında literatürde bulunan referans bir çalışmada [30] problemin zorluğu açıkça görülebilmektedir. İlgili çalışmada, eğitim verilerinin oluşturulmasında hedeflere ilişkin BDT modellerden de yararlanılmaktadır. 80 m ve üstü boya sahip gemilerin dikkate alındığı çalışmada sivil gemilerin yaklaşık %50 oranında askeri olarak sınıflandırıldığı görülmektedir.

RASES hesaplama aracı kullanılarak fiziksel optik (FO), seken ışın (shooting and bouncing rays, SBR) ve FO yöntemi ile ters yapay açıklıklı radar (TYAR) görüntüleme olmak üzere üç farklı biçimde sentetik menzil profilleri elde edilmiştir. Üretilen sentetik profiller üzerinde sınıflandırma çalışmaları öncesinde kuantalama, normalizasyon veya eşikleme gibi ön işlemler yapılmıştır.

Var olan benzetim ortamı sayesinde her türlü hedefe ilişkin her türlü deniz durumu koşulunda ve hedefin bulunabileceği her pozisyon ve yönde menzil profili verisi elde edilebilme imkanı bulunmaktadır. Ölçümsel olarak tüm hedef tiplerine ait istenilen her koşulda veri elde edilmesi imkansız olduğundan ve çok büyük bir uğraş gerektireceğinden benzetim ortamından elde edilecek verilerin sınıflandırma başarımının gerçek veriler ile kıyaslanması önemli bir girdi olarak düşünülmektedir.

Kullanılacak olan benzetim ortamında ortam şartlarının belirlenebilmesi ve hedefin çalışma uzayında istenen konum ve yönde konumlandırılabilmesi çalışma uzayını genişleterek başarımlarını karşılaştırmalarına girdi sağlamaktadır. Menzil profillerinin ardışıl ve sentetik olarak elde edilebilmesi için halihazırda kullanılmakta olan bir

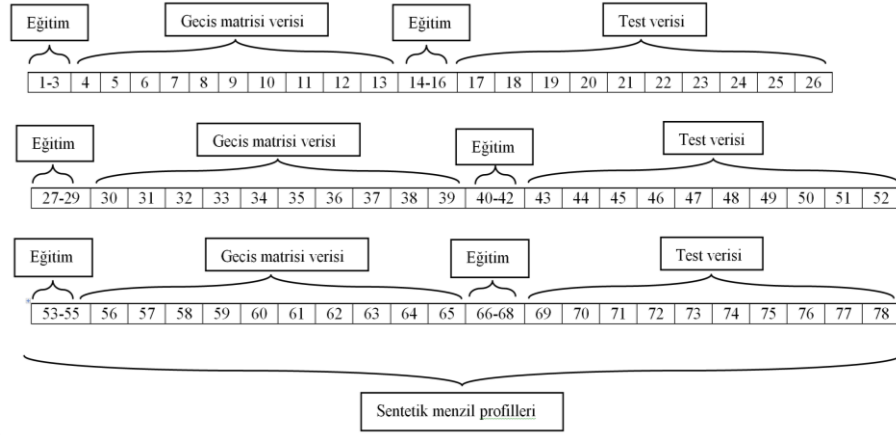
simülasyon yazılımından (RASES) destek alınmıştır. Simülasyon yazılımı herhangi bir 3 boyutlu nesnenin menzil profilini oluşturma yeteneğine sahiptir. 7 farklı hedefe ait menzil profilleri olabildiğince fazla bakış açısından alınmaya çalışılmıştır. Hedeflerin sınıflandırma kütüphanesinin başarımını zorlaması açısından birbirine yakın uzunluklarda ve benzer fiziksel özelliklere sahip örnekler seçilmiştir. Seçilen hedefler 4 tanesi sivil ve 3 tanesi askeri olmak üzere 7 farklı tipten oluşmaktadır. Çalışma kapsamında kullanılan hedeflere ait örnek üç boyutlu tasarım dokümanları Şekil 4.1 şeklinde görülmektedir.



Şekil 4.1. Sentetik olarak menzil profili elde edilen hedeflere ait 3 boyutlu tasarım dosyaları


Bahsi geçen hedeflere ait menzil profillerinin olabildiğince çeşitlilik göstermesi açısından 0.1 derece aralıklarla menzil profilleri üretilmiştir. Hedeflerin ön ve arka sektörlerine ait +45 derece ile -45 derece aralığında menzil profilleri üretilmiştir. Diğer yan yüzeylere ait profillerin gerçek hedef karakteristiğini göstermemesi sebebiyle üretim gerçekleştirilmemiş ve sınıflandırma testlerine tabi tutulmamıştır. Ön ve arka sektörlerden alınan 90'ar derecelik profiller toplamda 180 derecelik bir çeşitliliğe sahiptir. Profiller 0.1 derece aralıklarla üretilmiş ve her hedefe ait 1802 adet profil elde edilmiştir. 7 farklı hedef için toplamda 12614 adet profil üretimi gerçekleştirilmiştir. Tez kapsamında geliştirilen ardışıl menzil profili sınıflandırma çalışmasında ihtiyaç duyulan eğitim, geçiş matrisi ve test verilerinin tasniflenmesi gerekmektedir. Sentetik olarak elde edilen verilerin tasnifine ilişkin detaylı bilgi Şekil 4.2 şeklinde gözlemlenmektedir. Sentetik olarak elde edilen veriler eğitim, geçiş matrisi ve test verisi olarak gruplandırılmıştır. Geçiş matrisi ve test amacı ile kullanılacak verilerin ardışılık içermesi beklenmektedir. Ayrıca, +45 derece ile -45

derece aralığında eşit aralıklarla elde edilen sentetik verilerin gruplara ayrılması sırasında eğitim, geçiş matrisi ve test verilerinin homojen olarak dağıtılması hedeflenmiştir.



Şekil 4.2. Sentetik verinin eğitim, geçiş matrisi ve test gruplarına tasnifi


Her bakış açısı değerine karşılık gelen eğitim, geçiş matrisi ve test verilerinin seçilmesine olanak sağlayan tasnifleme işlemi Şekil 4.2 şeklinde açıklanmıştır.



Şekil 4.3. Kuru yük taşıyıcı hedef tipine ait menzil profilleri


Hedefler deniz hedefleridir ve kuru yük taşıyıcı, kargo, yat, balıkçı, Military Type-1, Military Type-2 ve Military Type-3 sınıflarını içermektedir. Askeri tip olan hedeflere ait detay bilgi askeri izin protokollerinden dolayı yayınlanmamaktadır. Bahse konu hedef sınıflarına ait 3D-CAD model dosyaları kullanılarak hedeflere ait menzil profilleri elde edilmiştir. Sentetik olarak 7 farklı sınıftan veri elde edilmiştir. Elde edilen verilerin içerisinde ilk sınıf kuru yük taşıyıcı sınıfıdır. İlgili sınıf ait menzil

profilleri Şekil 4.3 şeklinde görülmektedir. Hedef tiplerine ait menzil profillerinin sergilendiği şekillerde kullanılan genlik değeri normalize edilerek ve 0-1 aralığına çevrilerek çizdirilmiştir. Sentetik olarak elde edilen verilerin içerisinde ikinci sınıf kargo sınıfıdır. İlgili sınıfa ait menzil profilleri Şekil 4.4 şeklinde gözlemlenebilmektedir.



Şekil 4.4. Kargo hedef tipine ait menzil profilleri


Elde edilen verilerin içerisinde üçüncü sınıf yat sınıfıdır. İlgili sınıfa ait menzil profilleri Şekil 4.5 şeklinde gözlemlenebilmektedir.



Şekil 4.5. Yat hedef tipine ait menzil profilleri

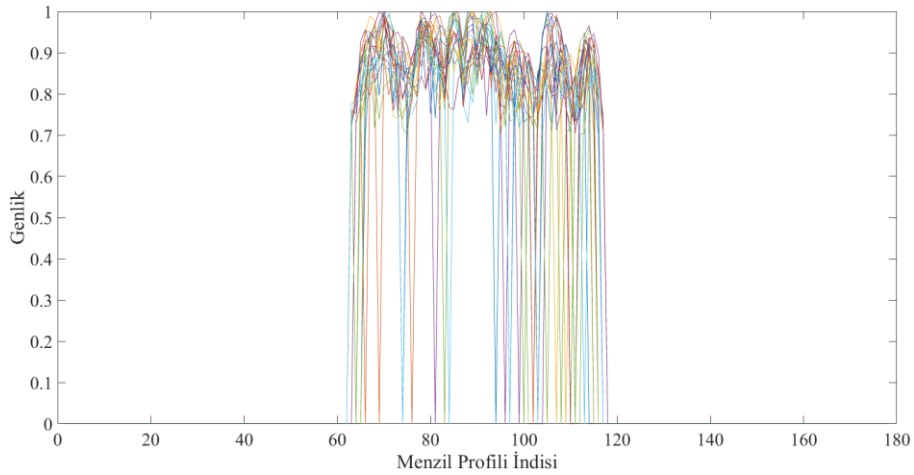
Sentetik olarak elde edilen verilerin içerisinde son sivil balıkçı sınıfıdır. İlgili sınıfa ait menzil profilleri Şekil 4.6 şeklinde gözlemlenebilmektedir. Yat sınıfına ait menzil profilleri incelendiğinde balıkçı sınıfına benzer genlik değerleri sergilediği gözlemlenmektedir. Tez kapsamında kullanılan hedef tiplerinin sınıflandırma

algoritmalarını zorlayıcı şekilde benzer fiziki ve genlik özellikleri içermesi amacı güdülmüş ve bu amaca uygun olarak seçilmiştir.




Şekil 4.6. Balıkçı hedef tipine ait menzil profilleri

Sentetik olarak elde edilen verilerin içerisinde askeri hedefler bulunmaktadır. Sentetik veri için kullanılan hedef sınıfı kümesinde beşinci sınıf olarak askeri Military Type-1 kod isimli sınıfa ait tasarım dosyaları kullanılmıştır. İlgili sınıfa ait menzil profilleri Şekil 4.7 şeklinde gözlemlenebilmektedir. Tez kapsamında kullanılan askeri hedef tiplerinin isimleri ve platform tipleri kod isimler ile belirtilmiştir.




Şekil 4.7. Military Type-1 hedef tipine ait menzil profilleri

Sentetik veri için kullanılan hedef sınıfı kümesinde altıncı sınıf olarak askeri Military Type-2 kod isimli sınıfa ait tasarım dosyaları kullanılmıştır. İlgili sınıfa ait menzil profilleri Şekil 4.8 şeklinde gözlemlenebilmektedir.



Şekil 4.8. Military Type-2 hedef tipine ait menzil profilleri

Sentetik veri için kullanılan hedef sınıfı kümesinde yedinci sınıf olarak askeri Military Type-3 kod isimli sınıfa ait tasarım dosyaları kullanılmıştır. İlgili sınıfa ait menzil profilleri Şekil 4.9 şeklinde gözlemlenebilmektedir. Şekilden de anlaşılacağı üzere menzil profillerinin üst üste çizdirilmesi sonucu sergilenen grafik alanda her bir menzil profilinin hedefin yansıtıcılık değerlerine bağlı olarak farklı karakteristikler sergilediği gözlemlenmektedir. Hedefin farklı bölgelerinde bulunan yansıtıcı bölgelerin farklı bakış açılarında farklı genlik değerleri (normalize) ürettiği gözlemlenmektedir.



Şekil 4.9. Military Type-3 hedef tipine ait menzil profilleri

4.2. Ardışıl Menzil Profillerinin Ölçümsel Olarak Elde Edilmesi

Bu tez kapsamında sınıflandırılması hedeflenen hedeflerin sahadan elde edilen menzil profili verilerinin elde edilmesi ve başarımlarının ölçülmesi

gerçekleştirilmiştir. Hali hazırda çalışmakta olan sistem çıktıları hedeflere ilişkin detaylı bilgi içermektedir. Farklı konumlarda konuşlandırılmış sistemler değişken deniz durumu koşulunda veri elde edilmesi olanağı sağlamaktadır. Verisi elde edilen hedefler, sistem ile olan mesafesi bakımından oldukça fazla çeşitlilik barındırmaktadır. Ayrıca, verisi elde edilen her hedefin rotasının ve hızının farklı olması sayesinde bakış açısı ve hız niteliği bakımından değişken veriler elde edilmiştir. Gerçek sistem üzerinde bu tarz bir verinin elde edilmesi çok uzun zaman ve uğraş gerektirmektedir. Her fırsat hedefinin uzun süre takip edilmesi ve 1 dakikalık zaman aralıklarında tekil menzil profili elde edilmesi sağlanmıştır. Elde edilen 2377 farklı menzil profilinin toplamda gerektirdiği süre oldukça fazladır. Verilerin elde edilmesi sırasında farklı mevzilerde çalışan radarlar kullanılmıştır.

Kullanılan benzetim ortamında ortam şartlarının belirlenebilmesi ve hedefin çalışma uzayında istenen konum ve yönde konumlandırılabilmesi sayesinde çalışma uzayı geniş tutulabilmektedir. Gerçek sistem verileri ile sentetik veri sınıflandırma başarımlarını karşılaştırmaları gözlemlenmiştir.


Bu tez çalışması kapsamında menzil profillerinin ardışıl ve gerçek saha verilerinden oluşacak şekilde elde edilebilmesi için çalışma gerçekleştirilmiştir. Sahadan elde edilen menzil profilleri olabildiğince fazla bakış açısından alınmaya çalışılmıştır. Hedeflerin sınıflandırma kütüphanesinin başarımlarını zorlaması açısından birbirine yakın uzunluklarda ve benzer fiziksel özelliklere sahip hedef tipleri takip edilmiştir.

Hedeflere ait menzil profillerinin olabildiğince çeşitlilik göstermesi açısından uzun bir süre boyunca hedefler takip edilmiştir. Hedeflere ait menzil profillerinin ön ve arka sektörlerine ait +45 derece ile -45 derece aralığında menzil profilleri üretilmiştir. Diğer yan yüzeylere ait profillerin gerçek hedef karakteristiğini göstermemesi sebebiyle üretim gerçekleştirilmemiş ve sınıflandırma testlerine tabi tutulmamıştır. Her bir radar farklı mevzilerde konuşlandırılmış bulunmasından dolayı farklı hedef tipleri ile karşılaşmaktadır. Elde edilen menzil profillerinin sınıflara göre envanter dökümü Tablo 4.1 tablosunda gözlemlenmektedir. 5 farklı gemi sınıfına ait toplam 171 farklı hedef radar imkanları dahilinde takip edilmiştir. Farklı mevzilerde konumlanmış radarlardan toplanan toplam 2377 adet verinin sınıflara göre dağılımı Şekil 4.10 şeklinde sergilenmiştir.

Tablo 4.1. Elde edilen menzil profillerinin sınıflara göre dağılımı

	Takip Edilen Hedef (adet)	Eğitim Verisi (adet)	Geçiş Matrisi Verisi (adet)	Test Verisi (adet)	Toplam Menzil Profili Sayısı (adet)
Military Type-4 (M1)	22	44	91	83	218
Military Type-5 (M2)	65	310	105	138	553
Military Type-6 (M3)	37	37	157	317	758
Kargo (M4)	29	82	164	166	412
Balıkçı (M5)	18	81	166	189	436
TOPLAM	171	674	843	860	2377

Gemi sınıflarından Military Type-4(M1) hedef tipinde 22 farklı hedef menzil profili üretimi amacıyla takip edilmiştir. M1 kodlu sınıf için veri toplama süreci içerisinde toplam 218 adet tekil menzil profili verisi üretilmiştir.



Şekil 4.10. Ölçümsel olarak elde edilen verilerin dağılımı

Bu veriler içerisinde ardışıklık özelliği taşıyan veriler geçiş matrisinin oluşturulması ve füzyon yönteminde test verisi olarak kullanılabilmesi amacıyla ayrılmıştır. Ardışıl ölçümsel veri tanımı bir hedefe ait sekiz veya daha fazla veri içeren veri grupları için kullanılmaktadır. M1 kodlu hedefe ait ardışıklık içermeyen 44 adet veri eğitim amacı ile kullanılmıştır. Ardışıklık içeren verilerden 91 adedi geçiş matrisi olasılıklarının


oluřturulması amacıyla kullanılmıřtır. M1 sınıfına ait 83 adet veri ise test verisi olarak kullanılmak üzere ayrılmıřtır.

M1 kodlu hedef için uygulanan veri tasnifi yöntemi diđer ölçümsel veri sınıfları için de kullanılmıřtır. Military Type-5(M2) hedef tipinde 65 farklı hedef menzil profili üretimi amacıyla takip edilmiřtir. M2 kodlu sınıf için veri toplama süreci içerisinde toplam 553 adet menzil profili verisi üretilmiřtir. Bu veriler içerisinde ardıřıllık özelliđi taşıyan veriler, füzyon yönteminde ihtiyaç duyulan geçiř matrisinin oluřturulması ve test verisi olarak kullanılabilmesi amacıyla ayrılmıřtır. M2 kodlu hedefe ait ardıřıllık içermeyen 310 adet veri eğitim amacı ile kullanılmıřtır. Ardıřıllık içeren verilerden 105 adedi geçiř matrisi olasılıklarının oluřturulması amacıyla kullanılmıřtır. M2 sınıfına ait 138 adet veri ise test verisi olarak kullanılmak üzere ayrılmıřtır.


Military Type-6(M3) hedef tipinde 37 farklı hedef menzil profili üretimi amacıyla takip edilmiřtir. M3 kodlu sınıf için veri toplama süreci içerisinde toplam 758 adet menzil profili verisi üretilmiřtir. Bu veriler içerisinde ardıřıllık özelliđi taşıyan veriler, füzyon yönteminde ihtiyaç duyulan geçiř matrisinin oluřturulması ve test verisi olarak kullanılabilmesi amacıyla ayrılmıřtır. M3 kodlu hedefe ait ardıřıllık içermeyen 37 adet veri eğitim amacı ile kullanılmıřtır. Ardıřıllık içeren verilerden 157 adedi geçiř matrisi olasılıklarının oluřturulması amacıyla kullanılmıřtır. M3 sınıfına ait 317 adet veri ise test verisi olarak kullanılmak üzere ayrılmıřtır.

Benzer veri tasnifi yöntemi Kargo (M4) için de uygulanmıřtır. M4 hedef tipinde 29 farklı hedef menzil profili üretimi amacıyla takip edilmiřtir. M4 kodlu sınıf için veri toplama süreci içerisinde toplam 412 adet menzil profili verisi üretilmiřtir. Bu veriler içerisinde ardıřıllık özelliđi taşıyan veriler, füzyon yönteminde ihtiyaç duyulan geçiř matrisinin oluřturulması ve test verisi olarak kullanılabilmesi amacıyla ayrılmıřtır. M4 kodlu hedefe ait ardıřıllık içermeyen 82 adet veri eğitim amacı ile kullanılmıřtır. Ardıřıllık içeren verilerden 164 adedi geçiř matrisi olasılıklarının oluřturulması amacıyla kullanılmıřtır. M4 sınıfına ait 166 adet veri ise test verisi olarak kullanılmak üzere ayrılmıřtır. Son olarak, Balıkçı M5 hedef tipinde 18 farklı hedef menzil profili üretimi amacıyla takip edilmiřtir. M5 kodlu sınıf için veri toplama süreci içerisinde toplam 436 adet menzil profili verisi üretilmiřtir.

Bu veriler içerisinde ardışıklık özelliği taşıyan veriler, füzyon yönteminde ihtiyaç duyulan geçiş matrisinin oluşturulması ve test verisi olarak kullanılabilmesi amacıyla ayrılmıştır. M5 kodlu hedefe ait ardışıklık içermeyen 81 adet veri eğitim amacı ile kullanılmıştır. Ardışıklık içeren verilerden 166 adedi geçiş matrisi olasılıklarının oluşturulması amacıyla kullanılmıştır. M4 sınıfına ait 189 adet veri ise test verisi olarak kullanılmak üzere ayrılmıştır.




Şekil 4.11. Ölçümsel olarak elde edilen balıkçı hedef tipine ait menzil profilleri




Şekil 4.12. Ölçümsel olarak elde edilen kargo hedef tipine ait menzil profilleri

Balıkçı hedef tipine ait elde edilen verilerin üst üste çizdirilerek sergilendiği Şekil 4.11 şeklinden de anlaşılacağı üzere veriler elde edildiği koşulların durumuna göre değişiklik göstermektedir. Her bir menzil profili alındığı ana ait karakteristik özellikler sergilemektedir. Elde edilen ölçümsel verilerin içerisinde ikinci sınıf olan

kargo hedef tipine ait menzil profilleri Şekil 4.12 şeklinde görülmektedir. Elde edilen ölçümsel verilerin içerisinde üçüncü sınıf olan Military Type-4 hedef tipine ait menzil profilleri Şekil 4.13 şeklinde görülmektedir. Sentetik verilere benzer olarak ölçümsel olarak elde edilen hedeflere ait platform tip ve isimleri de kod isimler ile değiştirilerek tez kapsamında kullanılmıştır.




Şekil 4.13. Ölçümsel olarak elde edilen Military Type-4 hedef tipine ait menzil profilleri



Şekil 4.14. Ölçümsel olarak elde edilen Military Type-5 hedef tipine ait menzil profilleri

Elde edilen ölçümsel verilerin içerisinde dördüncü sınıf olan Military Type-5 hedef tipine ait menzil profilleri Şekil 4.14 şeklinde görülmektedir. Elde edilen ölçümsel verilerin içerisinde dördüncü sınıf olan Military Type-6 hedef tipine ait menzil profilleri Şekil 4.15 şeklinde görülmektedir. Önceki şekillere benzer olarak Military Type-6 hedef tipine ait menzil profillerinin farklı bakış açıları farklı genlik

(normalize) deęerleri ürettięi gözlemlenmektedir. Genlik deęerlerinin farklı karakteristikler sergilemesi yansıtıcı yüzeylerin bakış açısına baęlı olarak deęişiklik göstermesi olarak deęerlendirilmektedir. Sentetik verilere benzer olarak sergilenen genlik deęerleri 0-1 aralığında sergilenecek şekilde indirgenmiştir.



Şekil 4.15. Ölçümsel olarak elde edilen Military Type-6 hedef tipine ait menzil profilleri

5. ARDIŞIL MENZİL PROFİLİ SINIFLANDIRMA ALGORİTMASINDAN ELDE EDİLEN SONUÇLAR

Bu tez çalışmasında radar verisinden elde edilen ham datanın işlenerek tespit edilen hedeflerin sınıflandırılması sağlanmaktadır. Radar ham verisi yapısı itibari ile birçok çevresel kaynaktan gelen ihtiyaç duyulmayan veri ile birlikte tespit edilen hedefe ait iz bilgisini içerir. Elde edilen iz bilgisi bir hedefin tespit edildiğini belirtse de hedefin kimliği hakkında bilgi vermez. Bu çalışma ile, uzak mesafelerdeki hedefler de dahil olmak üzere, elde edilen iz bilgisinden tespit edilen hedefe ait sınıf ve kimlik bilgilerine erişilebilmesi hedeflenmektedir. Tez kapsamında halihazırda çalışmakta olan yüksek çözünürlüklü bir radar sisteminden elde edilen gerçek hedeflere ait gerçek veriler kullanılmıştır. Kullanılan veriler tasniflenerek sınıflandırmaya uyumlu olan veriler eğitim ve test verisi olarak kümelendirilmiştir.

Gerçekleştirilen ardışıl veri kütüphanesi sayesinde aynı hedefe ait ardışıl veri kümeleri sınıflandırma çalışmalarında kullanılmıştır. Ardışıl veri kümelerinin gerçek radar sisteminden elde edilmesi aşamasında sistem kısıtı olan maksimum 12 adet ardışıl veri elde edilebilmiştir. Ardışıl verilerin geçiş matrisi oluşturmak amacıyla kullanılması ve geçiş matrisi olasılıklarını kullanan füzyon yöntemi geliştirimi ile maksimum başarıma ulaşılmaya çalışılmıştır.

Tez kapsamında hazırlanan sentetik veri kütüphanesi sayesinde ilgili ardışıl veri kümesinin benzetim ortamından sağlanmasının başarımı irdelenmiştir. Halihazırda çalışmakta olan sistemden elde edilen gerçek verinin fırsat hedeflerine dayalı olması sınıflandırma kütüphanesinin gelişmesinin önünde en büyük engel olarak düşünüldüğünden simüle verinin olası başarılı performansı sayesinde 3D tasarım dosyası olan her hedefe ilişkin verilerin kolaylıkla ve hızla üretilmesi büyük bir avantaj sağlamaktadır. Benzetim ortamının bir diğer faydası da elde edilecek verinin istenilen hedef pozisyonu ve açısında olmasına olanak sağlamasıdır. Ardışıl sınıflandırma sonucu oluşacak sınıflandırma vektörlerinin geçiş matrisi mimarisinde olasılık modeline oturtularak sınıflandırma mimarisinin otomatize edilmesi

sağlanmıştır. Sınıflandırma mimarisinin ön değerlendirme, kargaşa giderme, boyut azaltımı ve sınıflandırma metodolojisi bakımından mimarisi sunulmuştur. Tez sonucunda gerçek verilerin sınıflandırılması ve ardışıl verilerin sınıflandırma başarımına etkisi sentetik üretilen menzil profili verilerinin de katkıları ile analiz edilmiştir. Sentetik olarak elde edilen verilerin başarımı gerçek veriler ile yapılan çalışmaya ışık tutan ve başarımın arttığını gösteren bir çalışma olmuştur.

Deniz hedeflerinin 400 km gibi uzak sayılacak bir mesafeden tespit edilebilir olması ve göreceli olarak yavaş hareket eden hedefler olması sebebiyle 1 dk gibi kısa bir sürede elde edilecek ardışıl 12 verinin sınıflandırılması ve kombine sınıflandırma sonucunun derlenmesi uygulanabilirliğini arttırmaktadır. Ardışıl veriler alındığı anın bilgilerini içereceğinden birbirinden farklı hedef özelliklerini ve ortam bileşenlerini içereceğinden bir menzil profilinde gözden kaçırılması muhtemel ayrıntıların telafisine imkan sağlamaktadır. Ardışıl menzil profili sınıflandırılmasında füzyon algoritmasının kullanılmasının başarımı arttırdığı bu tez kapsamında yapılan çalışmalar sonucunda gözlenmiştir.

Bu tez kapsamında eğitim için kullanılacak veriler ile eğitilecek sınıflandırma servislerinin bulunduğu bir merkezi kütüphane oluşturulmasının uygun olacağı değerlendirilmektedir. Fiziksel olarak uzakta olan sorgulayıcı sistemlerin SOA yaklaşımını kullanarak merkezi kütüphaneden sorgulamayı gerçekleştirmesi ve ilgili sorguya karşılık gelen cevabı alması kavramsal mimari olarak sunulmaktadır. Merkezi kütüphanede sürekli olarak sorgu bekleyen servisler daha önceden belirlenmiş mesaj formatında gönderilen sorguları anlamlandırarak gerekli cevabı yine daha önce belirlenmiş mesaj formatı ile sorguyu gerçekleştiren internet protokol (IP) adresli sisteme iletmesi tasarlanmıştır.

Kurulacak sistemde radar sistemi ile merkezi kütüphanenin haberleşmesi SOA yaklaşımı kullanılarak gerçekleştirilmesi tasarlanmıştır. Haberleşme mekanizmasında halihazırda faaliyette olan radar sisteminin çıktıları anlamlandırılarak, uygun mesaj formatında merkezi kütüphaneden sorgulama işlemi gerçekleştirmesi tasarlanmıştır. Gerçek radar sisteminin çıktılarının anlamlandırılması ve merkezi kütüphaneden sorgulanması işlevini yürüten bir modül hazırlanmasının uygun olacağı değerlendirilmektedir. Gerçekleştirilmesi hedeflenen adımların tamamlanması ile

radar operatörlerinin tespit edilen her hedef hakkında bilgisi olması ve olası tehditlere karşı önceden önlem alınması için imkan sağlaması hedeflenmektedir. Ayrıca Türkiye'nin dört bir yanında konuşlu radar sistemlerinin karşılaştığı sistem tipleri farklılıklar göstermektedir. Merkezi hedef sınıfları kütüphanesi ile oluşturulması planlanan veritabanı ilgili tüm radar sistemlerinin ortak kullanımında olacağından daha önce karşılaşmadıkları sistem hakkında da bilgi sahibi konumuna gelmesini sağlayacaktır. Ayrıca, tüm radar sistemlerinin, kütüphaneden sadece sorgulama değil, aynı zamanda güncelleme ve ekleme yapabilmesi olanağına sahip olacağından kütüphanenin sürekli gelişmesi hedeflenmektedir.

İrdelenen dokümanların ve yapılan saha çalışmalarından elde edilen verilerin ardışıl olarak kümelenmesi tamamlanarak başarımlar raporumuzda raporlanmıştır. Gerçekleştirilen ve önerilen ardışıl menzil profili sınıflandırma algoritmasının literatürde yer alan ardışıl menzil profili sınıflandırma çalışmaları ile kıyaslanması çalışması gerçekleştirilmiştir. Aşağıda yer alan sonuç başlıklarında incelenen çıktılar hem sentetik, hem de ölçümsel veriler ile önerdiğimiz yöntemin başarımlarının yanısıra MVR ve BKS yöntemlerinin aynı veri seti için sergilediği başarımlarını da içermektedir.


5.1. Sentetik Veri İle Elde Edilen Sınıflandırma Sonuçları

Bu çalışmada 12614 adet ardışıl menzil profili verisi sentetik olarak üretilmiştir. Veriler eğitim, geçiş ve test gruplarına ayrılmıştır. Eğitim verileri PNN algoritmasını eğitmek için kullanılmıştır. Geçiş verileri geçiş matrisini üretmek için kullanılmıştır. Sentetik olarak üretilen verilerden elde edilen, yedi farklı hedefe ait sınıflandırma etiketleri arasındaki etkileşimi sergileyen ve geçiş olasılıklarının bulunduğu geçiş matrisi Tablo 5.1 tablosunda gösterilmektedir. Tabloda gösterildiği gibi, her hedef sınıfı, sınıflandırma işlemine bağlı olarak bir veya daha fazla sınıfla karıştırılmaktadır. Geçiş matrisi doğası gereği elde edilen olasılık değerleri sayesinde sınıfların birbiri ile ne kadar benzer oldukları fikrini bize sağlamaktadır. Her hedef tipinin düşük yada yüksek olasılıkla bir başka hedef olarak sınıflandırılması olasılığı sergilenmektedir. Geçiş matrisinde sergilenen sınıflara ait geçiş olasılıkları değerleri elde edilen veri grubuna özel olarak üretilmiştir. Veri grubu, tipi ve sıralamasının değiştirilmesi tekrar üretilmesini gerektirmektedir.

Tablo 5.1. Sentetik veri ve PNN algoritması ile elde edilen geçiş matrisi

	Yük Gemisi (S1)	Kargo (S2)	Yat (S3)	Balıkçı (S4)	Military Type-1 (S5)	Military Type-2 (S6)	Military Type-3 (S7)
Yük Gemisi (S1)	0,602	0,0035	0	0	0,204	0,19	0
Kargo (S2)	0,002	0,976	0	0,002	0,004	0	0,014
Yat (S3)	0	0	0,815	0,184	0	0	0
Balıkçı (S4)	0	0	0,1267	0,841	0,002	0	0,029
Military Type-1 (S5)	0,102	0,0062	0	0	0,621	0,269	0
Military Type-2 (S6)	0,144	0	0	0	0,273	0,579	0,002
Military Type-3 (S7)	0	0,015	0	0,038	0	0	0,946


Sentetik olarak elde edilen verilerinin PNN kullanılarak ardışıl menzil profili sınıflandırma algoritması kullanılmadan test edilmesi sonucu ortaya çıkan menzil profili sınıflandırma sonuçlarının özet görüntüsü Şekil 5.1 şeklinde görülmektedir.



Şekil 5.1. Sentetik veri ve PNN algoritması kullanılarak elde edilen menzil profili sınıflandırma sonuçları


PNN algoritması kullanılarak sentetik veriler ile gerçekleştirilen sınıflandırma performansı sonuçları incelendiğinde test edilen RP örneklerinin %79'unun doğru

sınıflandırıldığı gözlemlenmiştir. Bu çalışma kapsamında önceden tanımlanmış altı farklı öznelik kullanılmıştır. Ardışıl menzil profili verilerinin toplu olarak değerlendirildiği ve bu tez kapsamında önerilen füzyon algoritması bu adımda hariç tutulmuştur. PNN algoritması ve sentetik veri kullanılarak elde edilen karmaşa matrisleri başarı oranındaki artışı göstermektedir. Ayrıca sınıflandırma başarımının daha net ifadesi için literatürde precision, recall, f1 değerleri kullanılmaktadır. PNN sınıflandırıcı ve MVR metodu kullanılarak elde edilen sınıflandırma sonuçlarına ait precision, recall, f1 değerlerini içeren grafik Şekil 5.2 şeklinde sergilenmektedir.




Şekil 5.2. Sentetik veri ve PNN algoritması kullanılarak precision, recall, f1 sonuçları

PNN algoritması ve tarafımızdan geliştirilen füzyon algoritmasının sentetik üretilen menzil profili verilerine uygulanması sonucu oluşan sınıflandırma sonuçları Şekil 5.3 şeklinde sergilenmektedir.



Şekil 5.3. Sentetik veri, PNN algoritması ve füzyon algoritması kullanılarak elde edilen menzil profili sınıflandırma sonuçları

Bu adımda altı farklı öznitelik ve füzyon algoritması birlikte uygulanmıştır. Şekilden elde edilen sonuçlara göre sınıflandırma doğruluğuna füzyon algoritmasının pozitif yönde etki ettiği gözlemlenmektedir. Sınıflandırma doğruluğunun %79'dan % 87'ye yükseldiği gözlemlenmiştir. Şekil 5.3 şekline anlaşılabileceği üzere hedeflerin birbirini ile benzerlik göstermesinden ötürü sınıflandırma sonuçlarında hatalar yapıldığı gözlemlenmiştir. Füzyon algoritmasının yapılan hataları bu deney düzeneğinde %7 oranında azalttığı belirlenmiştir. Elde edilen sınıflandırma sonuçlarının başarımlarına ait bir başka gösterim de Şekil 5.4 şeklinde sergilenen grafiktedir.




Şekil 5.4. Sentetik veri, PNN algoritması ve füzyon algoritması kullanılarak elde edilen precision, recall, f1 sonuçları

Ardışıl test verileri sayesinde geçiş matrisi elde edilmiştir ve özgün sınıflandırma son işlem yöntemi ile başarımlar değişimleri gözlemlenmiştir. Elde edilen ardışıl veriler kullanılarak ardışıl sınıflandırma sonuçları üretilmekte ve profillerin sınıflandırma sonuçları derlenerek son işlemde geçirilerek sınıf etiketi ataması oluşturulmaktadır. Geçiş matrisi bir hedef tahmininden sonra hangi hedefin, hangi olasılıkla tahmin edilebileceğini işaret etmektedir. Gerçekleştirilen sınıflandırma sonucunun ardışıl verilerinin geçiş matrisi yardımıyla daha yüksek olasılıkla tahmin edilmesi sağlanmıştır. Ardışıl menzil profili sınıflandırma sonucu sınıf etiketleri dağılımında doğruluk artışı %8 oranında pozitif yönde gerçekleşmiştir. Ayrıca sınıflandırma sonuçlarının oluşturduğu karışıklık matrisleri yukarıdaki şekillerde görülmektedir.


Buna ek olarak literatürde karşılaşılan MVR metodu ile önerdiğimiz metodun karşılaştırmasını yapabilmek için aynı veri seti ile MVR metodunun çalıştırılması sağlanmıştır. Bu çalışmada önerilen metodun MVR metoduna oranla daha

başarılı bir oranla hedef tespiti gerçekleştirdiği gözlemlenmiştir. MVR metoduna ait çıktıları içeren karmaşıklık matrisi Şekil 5.5 şeklinde gözlemlenmektedir.



Şekil 5.5. Sentetik veri, PNN algoritması ve MVR metodu ile birlikte kullanılarak elde edilen menzıl profili sınıflandırma sonuçları

PNN sınıflandırıcı ve MVR metodu kullanılarak elde edilen sınıflandırma sonuçlarına ait precision, recall, f1 değerlerini içeren grafik Şekil 5.6 şeklinde sergilenmektedir. Sınıflandırma performansını ölçmek amacı ile üretilen precision, recall, f1 değerlerinin son işlem algoritmalarının uygulanması ile tekil sınıflandırma sonuçlarına kıyasla olumlu yönde değiştiği yorumu yapılabilmektedir.



Şekil 5.6. Sentetik veri, PNN algoritması ve MVR metodu ile birlikte elde edilen precision, recall, f1 sonuçları

5.2. Ölçüme Dayalı Veri İle Elde Edilen Sınıflandırma Sonuçları

Bu çalışmada yer alan tarama radarından 2377 menzıl profili verisi toplanmıştır. Veriler eğitim, geçiş ve test gruplarına ayrılmıştır. Eğitim verileri PNN ve CNN

algoritmalarını eğitmek için kullanılmıştır. Geçiş verileri, geçiş matrisi oluşturmak için kullanılmıştır. Ölçüme dayalı verilerin hem iki boyutlu hem de bir boyutlu veri içermesi sebebiyle verilerin sınıflandırma altyapısı hazırlanırken PNN ve CNN sınıflandırıcısı kullanılmıştır. Aşağıda listelenen sınıflandırma sonuçları ve performans karşılaştırmalarında precision, recall ve f1 grafiklerine ek olarak literatürde doğruluk (accuracy) olarak belirlenen ve doğru sınıflandırılan menzil profili sayısının tüm menzil profili sayısına oranını belirleyen değerler sunulacaktır.

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru sınıflandırma sayısı}}{\text{Toplam test profili sayısı}} \quad (5.1)$$

5.2.1. CNN sınıflandırıcı ile elde edilen sınıflandırma sonuçları

Ölçüme dayalı toplanan verilerden ve CNN sınıflandırıcısı kullanılarak elde edilen geçiş matrisi Tablo 5.2 tablosunda gösterilmiştir. Tabloda gösterildiği gibi, her hedef sınıf türü, sınıflandırma işlemine bağlı olarak bir veya daha fazla başka hedef sınıfla karıştırılır. Sınıflandırma verilerinin CNN (Convolutional Neural Network) kullanılarak test edilmesi sonucu ortaya çıkan menzil profili sınıflandırma sonuçlarının özet görüntüsü Şekil 5.7 şeklinde görülmektedir. Bu adımda tez kapsamında geliştirilen füzyon algoritması karşılaştırmaya girdi olması amacıyla kullanılmamıştır.

Aşağıdaki Yukarıdaki şekilde 5 farklı hedefe ait sınıflandırma sonucu bir arada gösterilmektedir. Şekilden de anlaşılacağı üzere birinci hedef olan balıkçı hedefine ait menzil profillerinin tamamı doğru sınıflandırılmıştır. İkinci hedef olan kargo gemisinin çoğunlukla M3 kodlu askeri sınıf ile karıştırıldığı gözlemlenmiştir. Üçüncü hedef olan M3 kodlu askeri sınıf tipi hedefe ait menzil profillerinin sınıflandırılmasında zaman zaman ikinci, dördüncü ve beşinci hedefler ile karıştırıldığı gözlemlenmiştir. Dördüncü hedef olan M4 kodlu askeri sınıfı hedefin üçüncü sınıf olan M3 kodlu askeri sınıf ve beşinci hedef olan M5 kodlu askeri hedefine benzerliği göze çarpmıştır. Beşinci hedef olan M5 kodlu askeri hedefinin M4 kodlu askeri sınıf ve M3 kodlu askeri sınıf tipi hedeflere benzerliği sınıflandırma sonuçları grafiğinden incelenebilmektedir. Ölçüme dayalı veri ve CNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına son işlem algoritması uygulamadan elde edilen doğruluk değerinin %74,04 olduğu gözlemlenmiştir.

	M1	M2	M3	M4	M5
M1	100				
M2	3.49	77.9	12.8	1.16	4.65
M3		8.33	86.67	5	
M4	6.06	1.51	34.85	28.79	28.79
M5		4.84	17.74	11.29	66.13

Şekil 5.7. Ölçüme dayalı veri ve CNN kullanılarak elde edilen menzil profili sınıflandırma sonuçları

Elde edilen ardışıl veriler kullanılarak bir hedefe ait ardışıl alınacak profillerin sonuçları derlenerek toplu sınıflandırma sonucu oluşturulmaktadır. Geçiş matrisi bir hedef tahmininden sonra hangi hedefin, hangi olasılıkla tahmin edilebileceğini işaret etmektedir.


Tablo 5.2. Ölçüme dayalı veri ve CNN algoritması ile elde edilen geçiş matrisi

	Balıkçı	Kargo	Military Type-4 (M1)	Military Type-5 (M2)	Military Type-6 (M3)
Balıkçı	0,97619	0,02381	0	0	0
Kargo	0	0,794643	0,160714	0,017857	0,026786
Military Type-4 (M1)	0	0,111842	0,730263	0,085526	0,072368
Military Type-5 (M2)	0	0,095238	0,309524	0,357143	0,238095
Military Type-6 (M3)	0	0,014286	0,142857	0,171429	0,671429

Gerçekleşecek sınıflandırma sonucunun ardışıl verilerinin geçiş matrisi yardımıyla daha yüksek olasılıkla tahmin edilmesine olanak sağlamaktadır. Elde edilen geçiş matrisine ait olasılık değerlerini içeren geçiş matrisi tablosu Tablo 5.2. tablosunda sergilenmektedir. Geçiş matrisinde bulunan olasılık değerleri ardışıl menzil


profillerinin tekil olarak sınıflandırılması sonucu oluşturulmaktadır. Ardışıl sınıflandırma sonuçları sonucu üretilen her bir sınıf etiketinin geçiş matrisinde duruma karşılık geldiği kabulü bulunmaktadır. Geçiş olasılıkları durumlar arası geçişlerin yoğunluğuna göre hesaplanmaktadır. Ardışıl menzil profillerinin tez kapsamında geliştirilen füzyon algoritması ve CNN sınıflandırıcı kullanılarak sınıflandırılması sonucu oluşan karışıklık matrisi Şekil 5.8 şeklinde görülmektedir.

Ölçüme dayalı veri ve CNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına AMPF algoritması uygulanması ile elde edilen doğruluk değerinin %84,85 olduğu gözlemlenmiştir. Tez kapsamında geliştirilen füzyon algoritmasının sınıflandırma doğruluğuna yaklaşık %11 oranında pozitif yönde etkisi olmuştur. Yukarıdaki şekilde 5 farklı hedefe ait sınıflandırma sonucu bir arada gösterilmektedir. Şekilden de anlaşılacağı üzere balıkçı, kargo gemisi ve M3 kodlu askeri sınıf hedef tiplerinin sınıflandırma doğruluğunun %100 olarak gerçekleştiği gözlemlenmektedir.




Şekil 5.8. Ölçüme dayalı veri, CNN ve füzyon algoritması kullanılarak elde edilen karışıklık matrisi

Hedeflere ait menzil profillerinin tamamı doğru sınıflandırılmıştır. Dördüncü hedef olan M4 kodlu askeri sınıf hedef tipinin başarımında bir miktar düşüş yaşanmıştır ve bunun sebebi olarak hedefe ait ölçümsel verinin az olması ve fiziksel olarak askeri diğer hedeflere benzerliği gösterilebilir. Beşinci hedef olan M5 kodlu askeri hedefinin sınıflandırma başarımında artış yaşanmıştır. Buna ek olarak literatürde karşılaşılan MVR metodu ile önerdiğimiz metodun karşılaştırmasını yapabilmek için aynı veri seti ile MVR metodunun çalıştırılması sağlanmıştır.



Şekil 5.9. Ölçüme dayalı veri, CNN ve MVR algoritması kullanılarak elde edilen karışıklık matrisi

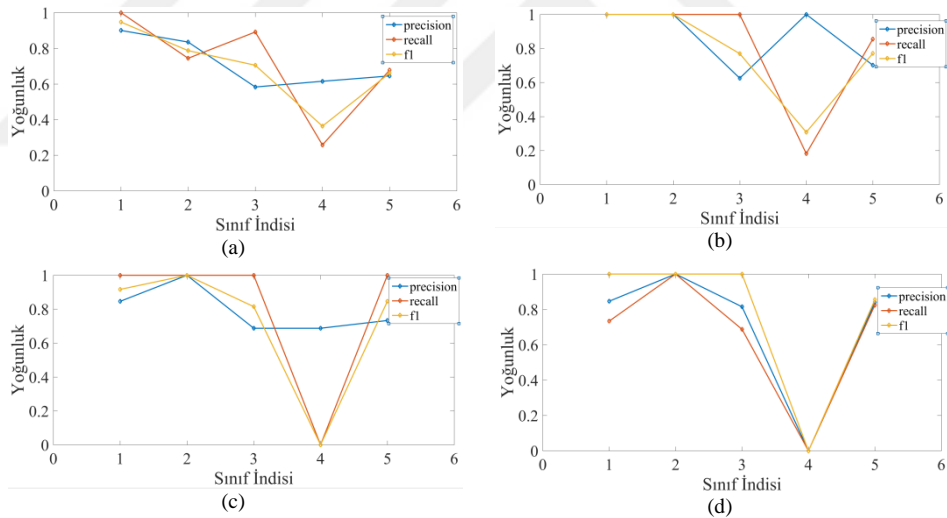
Ölçüme dayalı veri ve CNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına MVR algoritması uygulanması ile elde edilen doğruluk değerinin %81,34 olduğu gözlemlenmiştir. Bu çalışma kapsamında önerilen metodun, MVR metoduna oranla daha başarılı bir oranla hedef tespiti gerçekleştirdiği gözlemlenmiştir. MVR metoduna ait çıktıları içeren karmaşıklık matrisi Şekil 5.9 şeklinde gözlemlenmektedir.



Şekil 5.10. Ölçüme dayalı veri, CNN ve BKS algoritması kullanılarak elde edilen karışıklık matrisi

BKS yöntemi MVR metodu gibi sınıflandırma sonuçlarına son işlem olarak uygulanan ve literatürde karşılaşılan füzyon algoritmalarından biridir. Ölçümsel verilerin CNN sınıflandırıcıya tabi tutulması sonucu elde edilen sınıflandırma sonuçlarına BKS yönteminin son işlem olarak uygulanması Şekil 5.10 şeklinde gösterilmekte olan karışıklık matrisini üretmektedir. Ölçüme dayalı veri ve CNN

algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına BKS algoritması uygulanması ile elde edilen doğruluk değerinin %81,34 olduğu gözlemlenmiştir. BKS yöntemi kullanılarak gerçekleştirilen son işlem uygulaması sonucu M4 kod isimli hedefin sınıflandırma sonuçlarında diğer hedefler ile karıştırılarak doğru olarak sınıflandırılmadığı gözlemlenmiştir. Hedef sınıflandırma çalışmalarında performans metrikleri arasında sıkça yer verilen precision (kesinlik), recall (duyarlılık) ve f1 (kesinlik ve duyarlılığın harmonik ortalaması) değerleri CNN sınıflandırıcı ve ölçümsel veri seti için hesaplanmıştır. Hesaplama sonucu bahse konu değerlerde Şekil 5.11 şeklindeki gibi çıktılar gözlemlenmektedir. Şekil 5.11 dört farklı alt şekilden oluşmaktadır. Sırasıyla herhangi bir son işlem algoritması uygulanmadan (a), önerilen füzyon yöntemi kullanılarak (b), MVR metodu kullanılarak elde edilen (c) ve BKS yöntemi ile elde edilen (d) precision/recall/f1 grafikleridir. Aşağıdaki grafikler incelendiğinde tekil sınıflandırma sonuçlarına kıyasla son işlem algoritmalarının sınıflandırma performansı irdelenmiştir.




Şekil 5.11. Ölçümsel veri ve CNN sınıflandırıcı ile elde edilen precision, recall, f1 grafikleri

5.2.2. PNN sınıflandırıcı ile elde edilen sınıflandırma sonuçları

Ölçüme dayalı toplanan verilerden ve PNN sınıflandırıcısı kullanılarak elde edilen geçiş matrisi Tablo 5.3 tablosunda gösterilmiştir. Tabloda gösterildiği gibi, her hedef sınıf türü, sınıflandırma işlemine bağlı olarak bir veya daha fazla başka hedef sınıfla karıştırılır. Sınıflandırma verilerinin PNN (Probabilistic Neural Network) kullanılarak test edilmesi sonucu ortaya çıkan menzil profili sınıflandırma

sonuçlarının özet görüntüsü Şekil 5.12 şeklinde görülmektedir. Bu adımda tez kapsamında geliştirilen füzyon algoritması karşılaştırmaya girdi olması amacıyla kullanılmamıştır.



Şekil 5.12. Ölçüme dayalı veri ve PNN kullanılarak elde edilen menzil profili sınıflandırma sonuçları

Ölçüme dayalı veri ve PNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına herhangi bir son işlem algoritması uygulanmadan elde edilen doğruluk değerinin %81,34 olduğu gözlemlenmiştir.

Tablo 5.3. Ölçüme dayalı veri ve PNN algoritması ile elde edilen geçiş matrisi

	Balıkçı	Kargo	Military Type-4 (M1)	Military Type-5 (M2)	Military Type-6 (M3)
Balıkçı	0,891892	0,027027	0	0	0,081081
Kargo	0	0,746988	0,168675	0,060241	0,024096
Military Type-4 (M1)	0	0,083333	0,684524	0,107143	0,125
Military Type-5 (M2)	0	0,093023	0,372093	0,348837	0,186047
Military Type-6 (M3)	0,034483	0,022989	0,264368	0,057471	0,62069

İkinci hedef olan kargo gemisinin çoğunlukla M3 kodlu hedef tipi ile karıştırıldığı gözlemlenmiştir. M3 kodlu hedef tipinin zaman zaman ikinci, dördüncü ve beşinci hedefler ile karıştırıldığı gözlemlenmiştir. M4 kodlu hedefin çoğunlukla üçüncü hedefine benzerliği göze çarpmıştır. M5 kodlu hedefin M2 sınıfı hariç diğer sınıflar ile zaman zaman karıştırıldığı gözlemlenmektedir.

Elde edilen ardışıl veriler kullanılarak bir hedefe ait ardışıl alınacak profillerin sonuçları derlenerek toplu sınıflandırma sonucu oluşturulmaktadır. Geçiş matrisi bir hedef tahmininden sonra hangi hedefin, hangi olasılıkla tahmin edilebileceğini işaret etmektedir. Gerçekleşecek sınıflandırma sonucunun, geçiş matrisi yardımıyla daha yüksek olasılıkla tahmin edilmesine olanak sağlamaktadır. Geçiş matrisi olasılık değerleri Tablo 5.3 tablosunda sergilenmektedir.

	M1	M2	M3	M4	M5
M1	100				
M2		100			
M3			65.84	18.33	15.83
M4			4.55	95.45	
M5	14.52				85.48

Şekil 5.13. Ölçüme dayalı veri, PNN ve füzyon algoritması kullanılarak elde edilen karışıklık matrisi

Ardışıl menzil profillerinin tez kapsamında geliştirilen füzyon algoritması ve PNN sınıflandırıcı kullanılarak sınıflandırılması sonucu oluşan karışıklık matrisi Şekil 5.13 şeklinde görülmektedir. M1 ve M2 hedeflerin tamamının doğru sınıflandırıldığı karışıklık matrisi çıktısı olarak gözlemlenmiştir. Ölçüme dayalı veri ve PNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına AMPF işlem algoritması uygulanması ile elde edilen doğruluk değerinin %87,17 olduğu gözlemlenmiştir.

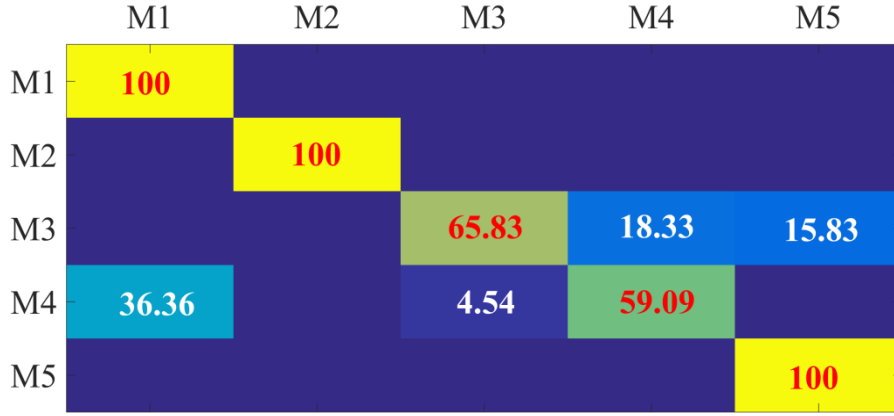
Yukarıdaki şekilden de anlaşılacağı üzere tez kapsamında geliştirilen füzyon algoritmasının sınıflandırma doğruluğunda %6 oranında pozitif yönde etkisi olmuştur. Yukarıdaki şekilde 5 farklı hedefe ait sınıflandırma sonucu bir arada

gösterilmektedir. Şekilden de anlaşılacağı üzere M1 ve M2 kodlu hedeflere ait sınıflandırma doğruluğunun %100 olarak gerçekleştiği gözlemlenmektedir. Hedeflere ait menzil profillerinin tamamı doğru sınıflandırılmıştır. Üçüncü ve dördüncü hedeflerin az miktarda da olsa birbiri ile benzerlik gösterdiği gözlemlenmiştir. Fiziksel olarak bu iki askeri hedef tipinin benzerlikleri sebep olarak değerlendirilmiştir.

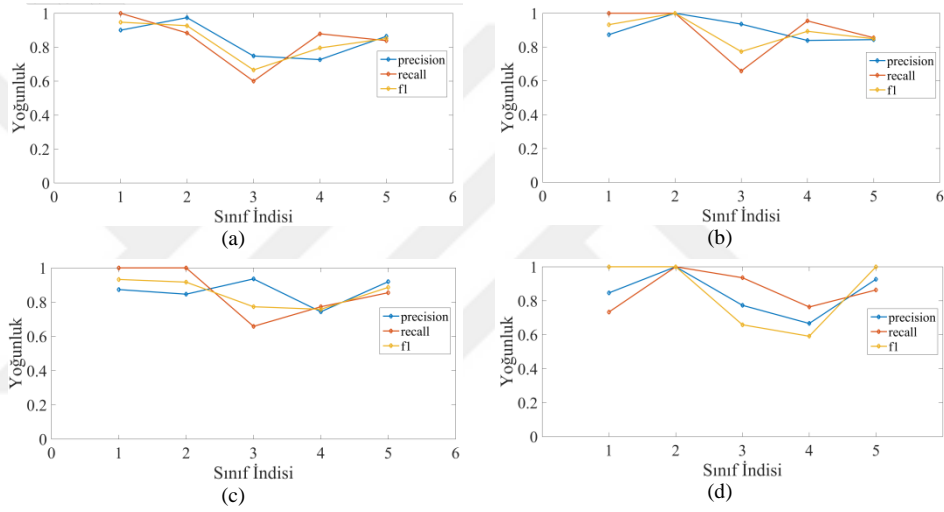
	M1	M2	M3	M4	M5
M1	100				
M2		100			
M3			65.83	26.67	7.5
M4		18.18	4.55	77.27	
M5	14.52				85.48

Şekil 5.14. Ölçüme dayalı veri, PNN ve MVR algoritması kullanılarak elde edilen karışıklık matrisi

Buna ek olarak literatürde karşılaşılan MVR metodu ile önerdiğimiz metodun karşılaştırmasını yapabilmek için aynı veri seti ile MVR metodunun çalıştırılması sağlanmıştır. Bu çalışma kapsamında önerilen metodun MVR metoduna oranla daha başarılı bir oranla hedef tespiti gerçekleştirdiği gözlemlenmiştir. MVR metoduna ait çıktıları içeren karmaşıklık matrisi Şekil 5.14 şeklinde gözlemlenmektedir. Ölçüme dayalı veri ve PNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına MVR algoritması uygulanması ile elde edilen doğruluk değerinin %83,66 olduğu gözlemlenmiştir. Ölçümsel verilerin PNN sınıflandırıcıya tabi tutulması sonucu elde edilen sınıflandırma sonuçlarına son işlem olarak BKS yönteminin uygulanması Şekil 5.15 şeklinde gösterilmekte olan karışıklık matrisini üretmektedir. BKS son işlem algoritması ile üretilen karışıklık matrisi M1, M2 ve M5 kodlu hedeflerin tamamının doğru olarak sınıflandırıldığını sergilemektedir. 3 hedefe ait tüm menzil profillerinin doğru sınıfa atandığı gözlemlenmiştir. Ölçüme dayalı veri ve PNN algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına BKS algoritması uygulanması ile elde edilen doğruluk değerinin %83,66 olduğu gözlemlenmiştir.



Şekil 5.15. Ölçüme dayalı veri, PNN ve BKS algoritması kullanılarak elde edilen karışıklık matrisi




Şekil 5.16. Ölçümsel veri ve PNN sınıflandırıcı ile elde edilen precision, recall, f1 grafikleri

PNN sınıflandırıcı ve ölçümsel veri seti için precision, recall ve f1 bilgilerini içeren hesaplamalar sonucu üretilen değerler Şekil 5.16 şeklinde gözlemlenmektedir. Şeklin sol üst köşesi PNN algoritması ve ölçümsel veri kullanılarak herhangi bir son işlem algoritması uygulanmadan elde edilen precision/recall/f1 grafiğidir (a). Sağ üst köşede ise tarafımızdan önerilen füzyon yöntemi sonucu oluşan grafiğdir (b). Sol alt köşede MVR metodu ile elde edilen sonuçlar sergilenmektedir (c). Son olarak şeklin sağ alt köşesinde BKS yöntemi ile elde edilen sonuçlar yer almaktadır (d).

5.2.3 YOLO V5 sınıflandırıcı ile elde edilen sınıflandırma sonuçları

Ölçüme dayalı toplanan verilerden ve YOLO V5 sınıflandırıcısı kullanılarak elde edilen geçiş matrisi Tablo 5.4 tablosunda gösterilmiştir. Tabloda gösterildiği gibi, her

hedef sınıf türü, sınıflandırma işlemine bağlı olarak bir veya daha fazla başka hedef sınıfla karıştırılmaktadır. Sınıflandırma verilerinin YOLO V5 (You Only Look Once) kullanılarak test edilmesi sonucu ortaya çıkan menzil profili sınıflandırma sonuçlarının özet görüntüsü Şekil 5.17 şeklinde görülmektedir. Ölçüme dayalı veri ve YOLO algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına son işlem algoritması uygulanmadan elde edilen doğruluk değerinin %91,99 olduğu gözlemlenmiştir. Aşağıdaki şekilde 5 farklı hedefe ait sınıflandırma sonucu bir arada gösterilmektedir. Şekilden de anlaşılacağı üzere birinci hedef olan balıkçı hedefine ait menzil profillerinin tamamı doğru sınıflandırılmıştır.



Şekil 5.17. Ölçüme dayalı veri ve YOLO V5 algoritması kullanılarak elde edilen karışıklık matrisi

İkinci hedef olan kargo gemisinin çoğunlukla M3 kodlu hedef tipi ile karıştırıldığı gözlemlenmiştir. M3 kodlu hedef tipinin zaman zaman ikinci, dördüncü ve beşinci hedefler ile karıştırıldığı gözlemlenmiştir. M4 kodlu hedefin çoğunlukla üçüncü hedefine benzerliği göze çarpmıştır. M5 kodlu hedefin M2 sınıfı hariç diğer sınıflar ile zaman zaman karıştırıldığı gözlemlenmektedir.

Ardışıl test verileri sayesinde geçiş matrisi elde edilmiştir. Geçiş matrisinde her sınıfın birbiri ile benzerli olasılık değerlerine ulaşmak mümkün olmaktadır. Örneğin matriste balıkçı ile kargo tiplerinin kesişim noktasından elde edilen olasılık değeri balıkçı olarak sınıflandırılan bir hedefin hangi olasılıkla kargo olarak seçilebileceğini belirtmektedir. Elde edilen geçiş matrisi Tablo 5.4. tablosunda görülmektedir. Elde edilen ardışıl veriler kullanılarak bir hedefe ait ardışıl alınacak profillerin sonuçları derlenerek toplu sınıflandırma sonucu oluşturulmaktadır. Geçiş matrisi bir hedef tahmininden sonra hangi hedefin, hangi olasılıkla tahmin edilebileceğini işaret


etmektedir. Gerçekleşecek sınıflandırma sonucunun, geçiş matrisi yardımıyla daha yüksek olasılıkla tahmin edilmesine olanak sağlamaktadır. Ardışıl menzil profillerinin tez kapsamında geliştirilen füzyon algoritması ve YOLO V5 sınıflandırıcı kullanılarak sınıflandırılması sonucu oluşan karışıklık matrisi Şekil 5.18 şeklinde görülmektedir.

Tablo 5.4. Ölçüme dayalı veri ve YOLO V5 algoritması ile elde edilen geçiş matrisi


	Balıkçı	Kargo	Military Type-4 (M1)	Military Type-5 (M2)	Military Type-6 (M3)
Balıkçı	0,928	0,047	0	0	0,023
Kargo	0,00893	0,9285	0,0446	0,0178	0
Military Type-4 (M1)	0	0,0333	0,8333	0,12	0,0133
Military Type-5 (M2)	0	0,02272	0,34090	0,36363	0,27272
Military Type-6 (M3)	0,014285	0	0,07142	0,1142	0,8

Yukarıdaki şekilden de anlaşılacağı üzere tez kapsamında geliştirilen füzyon algoritmasının sınıflandırma doğruluğuna %6 oranında pozitif yönde etkisi olmuştur. Yukarıdaki şekilde 5 farklı hedefe ait sınıflandırma sonucu bir arada gösterilmektedir. Şekilden de anlaşılacağı üzere M1 ve M2 kodlu hedeflere ait sınıflandırma doğruluğunun %100 olarak gerçekleştiği gözlemlenmektedir. Hedeflere ait menzil profillerinin tamamı doğru sınıflandırılmıştır. Üçüncü ve dördüncü hedeflerin az miktarda da olsa birbiri ile benzerlik gösterdiği gözlemlenmiştir. Fiziksel olarak bu iki askeri hedef tipinin benzerlikleri sebep olarak değerlendirilmiştir. Ölçüme dayalı veri ve YOLO algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarına AMPF algoritması uygulanması ile elde edilen doğruluk değerinin %93,89 olduğu gözlemlenmiştir. YOLO sınıflandırıcı kullanılarak elde edilen sınıflandırma sonuçlarından *precision*, *recall* ve *f1* değerleri ölçümsel veri seti için hesaplanmıştır. Elde edilen değerlere ilişkin sınıf bazlı değişim grafikleri Şekil 5.19 şeklinde

sergilenmektedir. Şekil 5.13 iki farklı alt şekilden oluşmaktadır. Şeklin sol tarafında YOLO algoritması ve ölçümsel veri kullanılarak herhangi bir son işlem algoritması uygulanmadan elde edilen precision/recall/f1 grafiği bulunmaktadır (a). Sağ kısımda ise tarafımızdan önerilen füzyon yöntemi sonucu precision/recall/f1 grafiğidir (b).



Şekil 5.18. Ölçüme dayalı veri, YOLO V5 ve füzyon algoritması kullanılarak elde edilen karışıklık matrisi



Şekil 5.19. Ölçümsel veri ve YOLO sınıflandırıcı ile elde edilen precision, recall, f1 grafikleri

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında geliştirilen algoritmanın başarımının ölçülmesi ve sistem mimarisinin oluşturulabilmesi adına çok aşamalı bir çalışma gerçekleştirilmiştir. Öncelikle literatür araştırmaları sonucunda ilgi duyulan alan konusundaki bilgi birikimi oluşturulmuş ve uygulanması hedeflenen yöntemin farkı ortaya çıkarılmıştır. 1975 yılından günümüze kadar olan akademik çalışmalar incelenmiş ve tez çalışmasına konu olacak çalışmanın altyapısı hazırlanmıştır.

Literatüre paralel olarak hedef sınıflandırma kütüphanesinin oluşturulmasında ilk adım olarak elde edilen verinin ön işleme safhasından geçirilmesi sağlanmıştır. Veri ön işlemenin ilk adımı olarak veri içerisindeki anomalilerin giderilmesi sağlanmıştır. Ardından elde edilen anomalileri giderilmiş verinin normalizasyonu sağlanmıştır. Sınıflandırma algoritmalarının başarımının daha sağlıklı bir şekilde ölçülebilmesi ve kullanılabilir veri elde etmek amacıyla veri üzerindeki kargaşanın giderilmesi çalışması gerçekleştirilmiştir. Sınıflandırma kütüphanesi tarafından kullanılacak özniteliklerin belirlenmesi aşaması ile veri ön işleme adımları tamamlanmıştır. Elde edilen veriler yapay PNN, CNN ve YOLO sınıflandırma algoritmalarına tabi tutulmuştur.

Literatür araştırmaları sonucunda karşılaşılan ardışıl menzil profili sınıflandırma çalışmalarından farklı olarak ortaya koyulan özgün yöntem içeriği ve metodolojisi ortaya konulmuştur. Tez kapsamında önerilen füzyon yönteminin metodolojisinde geçiş matrisi olasılıkları kullanılmıştır. Geçiş matrisinin oluşturulabilmesi için ardışıl olarak elde edilen verilerin ardışıl sınıflandırma sonuçları tasniflenerek olasılık değerlerine ulaşılmıştır. Belirlenen özgün yöntemin uygulanabilirliğinin ölçülmesi için sentetik olarak menzil profili üretme çalışması yapılmıştır. Sentetik olarak elde edilen veriler ve önerilen füzyon yöntemi ile elde edilen sonuçların dikkate değer başarımları sağlanması aynı metodun ölçümsel veri için de kullanılması

motivasyonunu sağlamıştır. Farklı mevkilere konuşlu radar istasyonlarında takip edilen hedeflere ait elde edilen ardışıl menzil profilleri kullanılarak füzyon yönteminin başarımı ölçümlenmiştir. Füzyon yönteminin ölçümsel veriler ile de gözle görülür başarımları sağladığı gözlemlenmiştir. Ölçümsel veriler ile elde edilen sınıflandırma sonuçlarının pekiştirilmesi amacıyla 3 farklı sınıflandırma algoritması geliştirilmiştir. CNN, PNN ve yakın geçmişte popülerliği artan YOLO sınıflandırıcıları ile başarımları ölçümleri gerçekleştirilmiştir. Her bir sınıflandırıcı ve veri kümesi için önerilen füzyon yönteminin sınıflandırma başarımını arttırdığı gözlemlenmiştir.

Kullanılan özniteliklerinin etki analizi gerçekleştirilmiştir. Tez kapsamında boy, en yüksek genlik değerinin uzaklık bilgisi, iki farklı en yüksek genlik değerinin uzaklığı, menzil profilindeki pik noktası sayısı, simetri bilgisi, yansıtıcılık değeri olmak üzere hedef fiziki özelliklerini ve yansıtıcılık değerlerinin çıktılarından oluşan 6 farklı öznitelik değeri kullanılmıştır.

Sentetik veri kullanılarak füzyon yöntemi başarımının ölçülmesi için PNN algoritması kullanılmıştır. Füzyon metodu uygulanmadan tekil menzil profilleri sınıflandırma sonuçlarına bakıldığında karışıklık matrisinin %79 oranında başarımlara ulaşıldığı gözlemlenmektedir. Füzyon yönteminin ardışıl profillere uygulanması sonrasında ise sınıflandırma doğruluğunun %87 seviyesine yükseldiği gözlemlenmektedir. Ardışıl menzil profillerinin özgün yöntem kullanılarak sınıflandırılması işlemi sırasında yine PNN sınıflandırıcı kullanılarak elde edilen durum geçiş matrisi olasılıkları kullanılmıştır. Sentetik veri ile elde edilen başarımların ölçümsel veri ile de elde edilip edilemeyeceğinin belirlenmesi amacıyla karaya konuşlu radarlar yardımı ile 171 farklı hedef takip edilmiştir. Takip edilen hedeflere ait ardışıl menzil profilleri tasniflenerek farklı sınıflandırma algoritmalarında başarımları değişimleri ölçümlenmiştir. Öncelikle ölçüme dayalı ardışıl veriler CNN sınıflandırıcı kullanılarak başarımları ölçümüne tabi tutulmuştur. CNN algoritması kullanılarak durum geçiş matrisi üretilmiştir. CNN algoritması, füzyon yöntemi ve geçiş matrisi olasılık değerleri kullanılarak sınıflandırma doğruluğunun %73'ten %83'e çıkarıldığı gözlemlenmiştir. Benzer bir

çalışmada ölçüme dayalı ardışıl veriler PNN sınıflandırıcı kullanılarak başarımlar ölçümüne tabi tutulmuştur. PNN sınıflandırma algoritması kullanılarak üretilen durum geçiş matrisi olasılık değerleri, PNN algoritması ve füzyon yöntemi kullanılarak sınıflandırma doğruluğunun %80'den %86'ya çıkarıldığı gözlemlenmiştir.

Tablo 6.1. PNN sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı

	Sınıf Kodu	Tekil Sınıflandırma	MVR	BKS	AMPF
Precision	M1	0,9001	0,8732	0,8462	0,8732
	M2	0,9741	0,8462	1	1
	M3	0,7481	0,9354	0,7728	0,9354
	M4	0,7267	0,7434	0,6661	0,8389
	M5	0,8642	0,9193	0,9266	0,8437
Recall	M1	1	1	0,7333	1
	M2	0,8837	1	1	1
	M3	0,6	0,6583	0,9354	0,6583
	M4	0,8788	0,7727	0,7632	0,9545
	M5	0,8387	0,8548	0,8633	0,8548
F1	M1	0,9474	0,9323	1	0,9323
	M2	0,9267	0,9167	1	1
	M3	0,6659	0,7728	0,6583	0,7728
	M4	0,7955	0,7578	0,5909	0,893
	M5	0,8513	0,8859	1	0,8492

Son olarak ölçüme dayalı ardışıl veriler YOLO sınıflandırıcı kullanılarak başarımlar ölçümüne tabi tutulmuştur. YOLO sınıflandırma algoritması kullanılarak üretilen durum geçiş matrisi olasılık değerleri, YOLO algoritması ve füzyon yöntemi kullanılarak sınıflandırma doğruluğunun %89'dan %91'e çıkarıldığı gözlemlenmiştir. Tüm bu sonuçlar ışığında hem sentetik veri kullanılarak hem de ölçümsel veriler kullanılarak elde edilen sınıflandırma başarımlar artışları tez kapsamında önerilen yöntemin uygulanabilirliğini kanıtlamıştır. Ayrıca yapılan çalışmalara yönelik üretilen bildiri ve makale çalışmaları ile literatüre katkı sağlanmıştır. Tablo 6.1 tablosunda PNN sınıflandırıcı ile tekil sınıflandırma, MVR, BKS ve AMPF yöntemleri

uygulanması sonucu elde edilen precision, recall ve f1 değerleri sınıf bazında sergilenmektedir. Önerilen yöntemin farklı veri tipleri ve farklı sınıflandırma algoritmaları ile uygulanmasında başarımların artışları değişkenlik gösterebilecektir. Yöntemin uygulanacağı alana uygun sınıflandırma algoritması belirlenmesi gerekmektedir. Bu değer yöntemin hangi alanda kullanılacağı bilgisine göre güncellenmesi gerekebilecektir. Tablo 6.2 tablosunda CNN sınıflandırıcı ile tekil sınıflandırma, MVR, BKS ve AMPF yöntemleri uygulanması sonucu elde edilen precision, recall ve f1 değerleri sınıf bazında sergilenmektedir. Tablo 6.3 tablosunda YOLO sınıflandırıcı ile tekil sınıflandırma, MVR, BKS ve AMPF yöntemleri uygulanması sonucu elde edilen precision, recall ve f1 değerleri sınıf bazında sergilenmektedir. YOLO ile gerçekleştirilen sınıflandırma çalışmalarında kullanılan sınıflandırma kütüphanesinin kısıtları gereğince sınıflandırma olasılık değerlerine erişilememesinden kaynaklı olarak MVR ve BKS yöntemleri uygulanamamıştır.

Tablo 6.2. CNN sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı

	Sınıf Kodu	Tekil Sınıflandırma	MVR	BKS	AMPF
Precision	M1	0,9004	0,8462	0,8462	1
	M2	0,8352	1	1	1
	M3	0,583	0,6875	0,8148	0,6251
	M4	0,6151	0,6875	0	1
	M5	0,645	0,7333	0,8395	0,7016
Recall	M1	1	1	0,7333	1
	M2	0,7442	1	1	1
	M3	0,8917	1	0,6875	1
	M4	0,2576	0	0	0,1818
	M5	0,6774	1	0,8246	0,8548
F1	M1	0,9476	0,9167	1	1
	M2	0,7871	1	1	1
	M3	0,7051	0,8148	1	0,7693
	M4	0,3631	0	0	0,3077
	M5	0,6608	0,8462	0,8548	0,7707

Tablo 6.3. YOLO sınıflandırıcı için precision, recall, f1 değerlerinin kullanılan algoritmalara göre dağılımı

	Sınıf Kodu	Tekil Sınıflandırma	MVR	BKS	AMPF
Precision	M1	0,8859	-	-	0,88
	M2	1	-	-	1
	M3	0,929	-	-	1
	M4	0,8751	-	-	1
	M5	0,7394	-	-	0,7253
Recall	M1	1	-	-	1
	M2	0,9418	-	-	1
	M3	0,9916	-	-	1
	M4	0,5606	-	-	0,4848
	M5	0,9032	-	-	1
F1	M1	0,9395	-	-	0,9362
	M2	0,97	-	-	1
	M3	0,9593	-	-	1
	M4	0,6834	-	-	0,6531
	M5	0,8132	-	-	0,8408

KAYNAKLAR

- [1] Xie D., Zhang X., Hu Y., Radar Target Recognition Using LVQ Network and Majority Voting, *2008 Congress on Image and Signal Processing*, Sanya, China, 184-187, 2008.
- [2] Kuncheva L., Combining Pattern Classifiers, Methods and Algorithms, 2nd ed., Wiley Press, New York, 132-142, 2014.
- [3] Zwicke P. E., Kiss I., A new implementation of the Mellin transform and its application to radar classification of ships, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, DOI:10.1109/TPAMI.1983.4767371.
- [4] Gui-Rong G., Wen-Xian Y., Wei Z., An intelligence recognition method of ship targets, *Fuzzy Sets and Systems*, 1990, **36**(1), 27-36.
- [5] Feixue W., Wenxian Y., Guirong G., Recurrent neural network for high-resolution radar ship target recognition, *CIE International Conference on Radar*, Beijing, China, 200-203, October 1996.
- [6] Serretta H., Inggs M. R., Ship target recognition with the Mellin transform aided by neural networks, *Communications and Signal Processing, COMSIG'98. Proceedings of the 1998 South African Symposium on*, Rondebosch, South Africa, 203-208, September 1998.
- [7] Inggs M. R., Robinson A. D., Ship target recognition with the Mellin transform aided by neural networks, *Communications and signal processing, COMSIG'98*, Rondebosch, South Africa, 203-208, September 1998.
- [8] Slomka S., Gibbins D., Gray D., Haywood B., Features for high resolution radar range profile based ship classification, *International Symposium on Signal Processing and its Applications (ISSPA '99)*, Brisbane, Australia, 1-4, August 1999.
- [9] Cotuk N., Ture S., Cetin M., "Application of point enhancement technique for ship target recognition by HRR", *SPIE AeroSense Symposium*, Orlando, USA, 185-193, April 2003.
- [10] Pilcher C., Khotanzad A., Nonlinear classifier combination for a maritime target recognition task, *2009 IEEE Radar Conference*, 1-5, May 2009.

- [11] Schimpf H., Fuchs H. H., Analysis of ATR features for non-cooperative ground-based classification of ships, *11-th International Radar Symposium (IRS)*, Vilnius, Lithuania, 1-5, June 2010.
- [12] Pilcher C. M., Khotanzad A., Maritime ATR using classifier combination and high resolution range profiles, *IEEE Transactions on Aerospace and Electronic Systems*, 2011, **47**(4), 2558-2573.
- [13] Liu X., Wang B., Xu X., Liang J., Ren J., Wei C., Multi-stage classification algorithm of ship target based on hrrp multi-features, *2011 6th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, Beijing, China, 2249-2253, June 2011.
- [14] Lu J., Xi Z., Yuan X., Yu G., Zhang M., Ship target recognition using high resolution range profiles based on FMT and SVM, *Proceedings of 2011 IEEE CIE International Conference on Radar*, Chengdu, China, 1299-1302, October 2011.
- [15] Schimpf H., Radar ATR of Maritime Targets, *IET Radar Sonar and Navigation, Radar Automatic Target Recognition (ATR) and Non-Cooperative Target Recognition (NCTR)*, **33**(6), 77-126, September 2013.
- [16] Alexandrov C., Draganov A., Kolev N., An application of automatic target recognition in marine navigation, *IEEE Radar Conference*, Alexandria, VA, USA, 250-255, May 1995.
- [17] Osman H. M., Pan L., Blostein S. Gagnon D., L., Classification of ships in airborne SAR imagery using backpropagation neural networks, *Optical Science, Engineering and Instrumentation*, California, USA, 126-136, August 1997.
- [18] Valin P., Tessier Y., Jauan A., Ship target recognition with the Mellin transform aided by neural networks, *Signals, Systems and Computers Conference*, 2, 1230-1234, USA, October, 1999.
- [19] Valin P., Bosse E., Jouan A., Airborne application of information fusion algorithms to classification, Technical Report, TR2004-282, *Defense Research and Development*, Valcartier, Canada, 2006.
- [20] Pastina D., Spina C., Multi-feature based automatic recognition of ship targets in ISAR, *IET radar, sonar & navigation*, **3**(4), 406-423, 2009.
- [21] Sathyendra H. M., Stephan B. D., Automated radar image target recognition based on segmented feature extraction using adaptive Length Estimation and Hough lines aiding optimized Neural Network classification, *2013 IEEE Radar Conference (RadarCon13)*, Ottawa, ON, Canada, 1-5, April 2013.

- [22] Zhongliang Q., Wenjun W., Automatic ship classification by superstructure moment invariants and two-stage classifier, *Singapore ICCS/ISITA'92. Communications on the Move*, Singapore, 544-547, November 1992.
- [23] Chuaysi B., Kiattisin S., Leelasantitham A., Wongseree W., Warship Classification from Distant View Using Dynamic Time Warping and K-NN, *Msc. Thesis*, Mahidol University, Bangkok, Thailand, 2013.
- [24] Jun L., Wen Xian Y., Gui Rong G., Feature extraction for radar ship target recognition using compactly supported wavelets, *Aerospace and Electronics Conference, NAECON 1994*, Dayton, USA, 66-73, May 1994.
- [25] Robinson A. D., Ship target recognition, University of Cape Town, PhD Thesis, South Africa, 1996.
- [26] Inggs M. R., Robinson A. D., Hierarchical ship classifier for airborne synthetic aperture radar (SAR) images, *IEEE Transactions on Aerospace and Electronic Systems*, **35**(2), 386-393, 1999.
- [27] Trevor P. J., Malvern Q., Ship Classification by Radar Range Profiles using the Maximum Likelihood Method", Technical Report, *QinetiQ Malvern*, 2001.
- [28] Pilcher C., Khotanzad A., Statistical performance of classifiers for a maritime ATR Task, *National Aerospace and Electronics Conference, NAECON*, Dayton, OH, USA, 163-167, July 2008.
- [29] Liu X., Wang B., Xu X., Liang J., Ren J., Wei C., Modified nearest neighbor fuzzy classification algorithm for ship target recognition, *2011 6th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, Beijing, China, 2254-2258, June 2011.
- [30] Jasinski T., Antipov I., Monteiro S. T., Brooker G., W-band maritime target classification using high resolution range profiles, *2013 International Conference on Radar*, Adelaide, SA, Australia, 356-361, September 2013.
- [31] Klepko R., Classification of SAR ship images with the aid of a syntactic pattern recognition algorithm, Technical Report, *Defence Research Establishment*, DREO-TN-91-10, Ottawa, 1991.
- [32] Liu Y., Zhang X., Shao J., Quadratic time-frequency feature extraction and fusion for ship targets classification, *12th International Conference on Signal Processing*, Hangzhou, China, 194-198, October 2014.

- [33] Li K. D., Zhang Y. Y., Li Y. J., Researches of sea surface ship target auto-recognition based on wavelet transform, *Proceedings of the 2010 International Conference on System Science, Engineering Design and Manufacturing Informatization (ICSEM)*, Yichang, China, 193-195, November 2010.
- [34] Ning J., Jie F., Maritime Target Recognition Based on Fuzzy Clustering Analytical Method, *Intelligent System Design and Engineering Application (ISDEA)*, Sanya, China, 341-344, January 2012.
- [35] Inggs M. R., Robinson A. R., Neural approaches to ship target recognition, *IEEE Radar Conference*, Alexandria, VA, USA, 386-391, May 1995.
- [36] Liao K., Gui G., Chen Z., Yang W., High resolution range profile based extraction of radar target length, *International Journal of Physical Sciences*, 2011, **6**(23), 5503-5510.
- [37] Gouaillier V., Gagnon L., Ship silhouette recognition using principal components analysis, *Optical Science, Engineering and Instrumentation*, California, USA, 59-69, August 1997.
- [38] Sathyendra H. M., Stephan B. D., Effects of using enhanced input range profiles for 1-d automated maritime vessel classification, *IEEE Radar Conference*, Cincinnati, OH, USA, 0112-0117, May 2014.
- [39] Zhao Z., Ji K., Xing X., Chen W., Zou H., Ship classification with high resolution terrasar-x imagery based on analytic hierarchy process, *International Journal of Antennas and Propagation*, 2013, 1-13.
- [40] Gagnon L., Klepko R., Hierarchical classifier design for airborne SAR images of ships, *International Symposium on Aerospace/Defense Sensing and Controls*, Orlando, Florida, USA, 38-49, April 1998.
- [41] Deng L., Yu D., Deep Learning: Methods and Applications, *Foundation and Trends in Signal Processing*, **7**, 197-387, 2014.
- [42] Le Q. V., Ranzato M., Monga R., Devin M., Chen K., Corrado G. S., Dean J., Ng A. Y. Building High-Level Features Using Large Scale Unsupervised Learning, *Proceedings of the 29th International Conference on Machine Learning*, Edinburgh, 2012.
- [43] Taigman Y., Yang M., Ranzato M., Wolf L., DeepFace: Closing the Gap to Human-Level Performance in Face Verification”, *Conference on Computer Vision and Pattern Recognition (CVPR)*, 2014.

- [44] Amodei D., Ananthanarayanan S., Anubhai R., Bai J., Battenberg E., Case C., Casper J., Catanzaro B., Cheng Q., Chen G., Chen J., Chen J., Chen Z., Chrzanowski M., Coates A., Diamos G., Ding K., Du N., Elsen E., Zhu Z., *Deep Speech 2: End-to-End Speech Recognition in English and Mandarin*, arXiv:1512.02595, 2015.
- [45] Malik S., Kim D., A Comparison Of Restful Vs. SOAP Web Services In Actuator Networks, *2017 Ninth International Conference on Ubiquitous and Future Networks (ICUFN)*, Milan, Italy, 753-755, 2017.
- [46] Strang G., Nyugen T., *Wavelets and Filter Banks*, Wellesley-Cambridge Press, Massachusetts, 1997.
- [47] Arivazhagan S., Jebarani W. S. L., Kumaran G., Performance comparison of discrete wavelet transform and dual tree discrete wavelet transform for automatic airborne target detection, *International Conference on Computational Intelligence and Multimedia Applications*, Sivakasi, India, 495-500, 2007.
- [48] Theodoridis S., Koutroumbas K., *Pattern Recognition*, Elsevier Academic Press, Second Press, 2003.
- [49] Haykin S., *Neural Networks: A Comprehensive Foundation*, Macmillan College Publishing, New York, 1994.
- [50] Avci M., Yildırım T., Classification of Escherichia Coli Bacteria by Artificial Neural Networks, *IEEE International Symposium on Intelligent Systems*, Varna, Bulgaria, **3**, 16-20, 2002.
- [51] Wong H. S., Wu M., Joyce R. A., Guan L., Kung S. Y., A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems, *Proceedings of IEEE Pacific RIM Conference on Multimedia*, Sydney, Australia, 2000.
- [52] Chen J. S., Walton E. K., Comparison of two target classification techniques, *IEEE Transactions on Aerospace and Electronic Systems*, 1986, **AES-22**(1), 15-22.
- [53] Libby, E. W. Application of sequence comparison methods to multisensor data fusion and target recognition, Ph.D. Thesis, Air Force Institute of Technology, 1993.
- [54] Zyweck A., Bogner R. E., Coherent averaging of range profiles. *Record of the IEEE 1995 International Radar Conference*, Alexandria, VA, 456-461 and 794, May 1995.
- [55] Jacobs S.P., O'Sullivan J.A., Automatic Target Recognition Using Sequence of High Resolution Radar Range Profiles. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, **36**(2), 364-381.

- [56] Enoki S., Shibuya T., Yano H., Classification for sequential data involving human trial and error, *56th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, Kanazawa, Japan, 1284-1289, 2017.
- [57] RASES, Türkiye Bilimsel ve Teknolojik Araştırma Kurum (TÜBİTAK), Bilişim ve Bilgi Güvenliği İleri Teknolojiler Araştırma Merkezi (BİLGEM), www.bilgem.tubitak.gov.tr/en/urunler/rases-radar-cross-section-computation (Ziyaret Tarihi : 21 Nisan 2020).
- [58] Nilubol C., Pham Q.H., Mersereau R.M., Smith M.J.T., Clements M.A., Hidden Markov Modelling For SAR Automatic Target Recognition. *IEEE International Conference on Acoustics, Speech and Signal Processing*, Seattle, WA, USA, 1998, 1061-1064 .
- [59] FSCNCA, Feature Selection Using Neighborhood Component Analysis, <https://ch.mathworks.com/help/stats/fscnca.html> (Ziyaret Tarihi : 21 Aralık 2020).
- [60] Cui, J., Gudnason, J., Brookes, M. (2008) Hidden Markov Models For Multi-Perspective Radar Target Recognition, *2008 IEEE Radar Conference, 008 IEEE Radar Conference*, Rome, Italy, 1-5, 2008.
- [61] Kouemou G., Opitz F., Impact of Wavelet Based Signal Processing Methods in Radar Classification Systems Using Hidden Markov Models, *2008 International Radar Symposium*, Wroclaw, Poland, 1-4, 2008.
- [62] Binesh T., Supriya M. H., Pillai P. R. S., State Transition Matrix for an HMM based underwater target classifier, *2009 International Symposium on Ocean Electronics (SYMPOL 2009)*, Cochin, 66-71, 2009.
- [63] Kahler B., Blasch E., Robust Multi-Look HRR ATR Investigation Through Decision-Level Fusion Evaluation, *11th International Conference on Information Fusion*, Cologne, Germany, 1-8, 2008.
- [64] Cho H., Chun J., Lee T., Lee S., Chae D., Spatiotemporal Radar Target Identification Using Radar Cross-Section Modeling And Hidden Markov Models, *IEEE Transactions on Aerospace and Electronic Systems*, 2016, **52**(3), 1284-1295.
- [65] Huan R.H., Pan Y., Target Recognition for Multi-Aspect SAR Images with Fusion Strategies, *Progress In Electromagnetics Research*, 2013, **134**, 267-288.
- [66] Liu J., Fang N., Xie Y. J., Wang B. F., Multi-Scale Feature-Based Fuzzy-Support Vector Machine Classification Using Radar Range Profiles, *IET Radar, Sonar & Navigation*, 2013, **10**(2), 370-378.

- [67] Xie D., Zhang X., Hu Y., Radar Target Recognition Using LVQ Network and Majority Voting, *2008 Congress on Image and Signal Processing*, Sanya, China, 184-187, 2008.
- [68] Laterveer R., Hughes D., Dugelay S., Markov random fields for target classification in Low Frequency Sonar, *IEEE Oceanic Engineering Society. OCEANS'98. Conference Proceedings*, 1998, 1274-1278.
- [69] Runkle P. R., Bharadwaj P. K., Couchman L., Carin L., Hidden Markov Models For Multiaspect Target Classification, *IEEE Transactions on Signal Processing*, 1999, **47**(7), 2035-2040.
- [70] Dasgupta N., Runkle P., Carin L., Class-based identification of underwater targets using hidden Markov models, *2001 IEEE International Conference on Acoustics, Speech, and Signal Processing*. Salt Lake City, UT, USA, 3161-3164, 2001.
- [71] Lopera, O., Dupon, Y., Target classification from HR sonar images, *2013 MTS/IEEE OCEANS – Bergen*, Bergen, Norway, 1-6, 2013.
- [72] Vespe M., Baker C.J., Griffiths H.D., Radar target classification using multiple perspectives, *IET Radar, Sonar & Navigation*, 2007, **1**(4), 300-307.
- [73] Ji S., Liao X., Carin L., Adaptive Multi-Aspect Target Classification And Detection With Hidden Markov Models. *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Montreal, Canada, ii-125, 2004.
- [74] Theodoridis S., Piskrakis A., Koutroumbas K., Cavouras D., *Introduction to Pattern Recognition: A Matlab Approach*, Academic Press, 107, 2010.
- [75] Coşkun N., Elektronik Retina Tasarımına Uygun Yapay Sinir Ağı Yapısının Arastırılması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, 2003, 139682.
- [76] Lippman R. P., An Introduction to Computing with NeuralNets, *IEEE ASSP Magazine*, 1987, 4-22.
- [77] Hinton G. E., Connectionist Learning Procedures, *Artificial Intelligence*, 1989, **40**(2), 185-234.
- [78] Goh T. C., Probabilistic Neural Network for Evaluating Seismic Liquefaction Potential, *IEEE International Symposium On Intelligent Systems*, Varna, Bulgaria, **3**, 16-20, 2002.
- [79] Turaga S., Murray J., Jain V., Roth F., Helmstaedter M., Briggman K., Denk W., Seung H., Convolutional networks can learn to generate affinity graphs for image segmentation, *Neural Computation*, 2010, **22**(2), 511–538.

- [80] Schalkoff R. J., *Artificial Neural Networks*, McGraw-Hill Inc., Singapore, 1997.
- [81] Ksienski A. A., Lin Y.T., White, L. J., Low-frequency approach to target identification. *Proceedings of the IEEE*, 1975, **63**(12), 1651-1659.
- [82] Abou-Moustafa K.T., Suen C.Y., Cheriet M., A Generative Discriminative Hybrid For Sequential Data Classification, *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Montreal, Canada, 2004.
- [83] Pei B., Bao Z., Multi-Aspect Radar Target Recognition Method Based On Scattering Centers And HMMs Classifiers, *IEEE Transactions on Aerospace and Electronic Systems*, 2005, **41**(3), 1067-1074.
- [84] Wang H., Li S., Zhou Y., Chen S., SAR Automatic Target Recognition Using a Roto-Translational Invariant Wavelet-Scattering Convolution Network, *Remote Sensing*, 2018, **10**(501).
- [85] Bati B., Duru N., Sequential Naval Target Range Profile Classification Using Special Fusion Method, *4th International Conference on Computer Science and Engineering (UBMK)*, Samsun, Turkey, 475-477, 2019.
- [86] Bati B., Duru N. Maritime Automatic Target Recognition For Ground Based Scanning Radars By Using Sequential Range Profiles. *Turkish Journal Of Electrical Engineering & Computer Sciences.* , vol. 29, pp. 929-943, 2021, doi: 10.3906/elk-2004-143.

KİŞİSEL YAYIN VE ESERLER

B. Bati, N. Duru, "Maritime automatic target recognition for ground based scanning radars by using sequential range profiles" in *Turkish Journal Of Electrical Engineering & Computer Sciences*, 2021, **29**, 929-943.

B. Bati, N. Duru, "Sequential Naval Target Range Profile Classification Using Special Fusion Method," *2019 4th International Conference on Computer Science and Engineering (UBMK)*, Samsun, Turkey, 475-477, 2019.

O. Karabayır, U. Saynak, M. Z. Kartal, A. F. Coşkun, T. O. Gulum and **B. Bati**, "Synthetic-Range-Profile-Based Training Library Construction for Ship Target Recognition Purposes of Scanning Radar Systems," in *IEEE Transactions on Aerospace and Electronic Systems*, 2020, **56**(4), 3231-3245.

B. Bati, P. O. Durdu. "Rapsim Web Sitesi Kullanılabilirlik Araştırması : Bir Durum Çalışması," *8. Ulusal Yazılım Mühendisliği Sempozyumu (UYMS)*, Güzelyurt, Cyprus(KKTC), 45-54, 2014.

S. Aldırmaz, U. Saynak, O. Karabayır, A. Coskun, H. Serim, S. Karahan, M. Unal, **B. Bati**, Ö. Bati, A. Çolak, D. Bolukbas, K. Hocaoglu", Wind turbine effects on radar performance," *2013 21st Signal Processing and Communications Applications Conference (SIU)*, Haspolat, 1-4, 2013.

O. Karabayır, U. Saynak, A. F. Coskun, **B. Bati**, M. Biyik, O. Bati, ..., S. Kent, "Synthetic Aperture Radar (SAR) Imaging of Complex Scenes Considering Near-Field Scattering Characteristics", *EUSAR 2016: 11th European Conference on Synthetic Aperture Radar*, Hamburg, Germany, 1-4, 2016.

A. F. Coşkun, U. Saynak, O. Karabayır, M. Biyik, **B. Bati**, O. Bati, H. A. Serim, "Statistical modeling of wind turbines' bi-static free-space scattering characteristics for UHF-band applications", *Microwave Symposium (MMS), 2015 IEEE 15th Mediterranean*, Lecce, Italy, 1-4, 2015.

O. Karabayır, M. Unal, A. F. Coskun, S. M. Yucedag, U. Saynak, **B. Bati**, ..., S. Kent, "CLEAN based wind turbine clutter mitigation approach for pulse-Doppler radars", *Radar Conference (RadarCon)*, Arlington, VA, USA, 1541-1544, 2015.

ÖZGEÇMİŞ

Baki BATI lise öğrenimini Ankara Bahçelievler Cumhuriyet Lisesi'nde tamamladı. 2005 yılında girdiği Ege Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2010 yılında mezun oldu. 2006 yılında Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği yüksek lisans eğitimine başladı. Yüksek lisans eğitimini 2009 yılında tamamlayıp askerlik görevini yerine getirmek üzere orduya katıldı. 2013 yılında Kocaeli Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı'nda doktora öğrenimine başladı. Doktora öğrenimi sürecinde deniz hedeflerinin otomatik olarak sınıflandırılması konusunda çalışmalar gerçekleştirdi. Ayrıca, 2005 yılında TÜBİTAK BİLGEM'de araştırmacı olarak başladığı iş hayatına başuzman araştırmacı olarak halen devam etmektedir.