BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK/ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK/ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

DARBELİ RADAR SİNYALLERİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE TANIMLANMASI

HAZIRLAYAN

MERT DEMİRCAN

YÜKSEK LİSANS TEZİ

ANKARA - 2024

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK/ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK/ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

DARBELİ RADAR SİNYALLERİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE TANIMLANMASI

HAZIRLAYAN

MERT DEMİRCAN

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DOÇ. DR. AHMET GÜNGÖR PAKFİLİZ

ANKARA – 2024

BAŞKENT ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik/Elektronik Mühendisliği Anabilim Dalı Elektrik/Elektronik Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Mert Demircan tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 15 / 04 / 2024

Tez Adı: Darbeli Radar Sinyallerinin Makine Öğrenmesi Algoritmaları ile Tanımlanması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu) **İmza**

Doç. Dr. Ahmet Güngör PAKFİLİZ, Ostim Teknik Üniversitesi ……..

Prof. Dr. Sıtkı Çağdaş İNAM, Başkent Üniversitesi ……..

Dr. Öğr. Üyesi Ahmet ÖZDİL, Ostim Teknik Üniversitesi ……..

ONAY

Prof. Dr. Ömer Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih: … / … / ….…….

BAŞKENT ÜNİVERSİTESİ

FEN BİLİMLER ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ÇALIŞMASI ORİJİNALLİK RAPORU

Tarih: 03 / 04 / 2024

Öğrencinin Adı, Soyadı: Mert DEMİRCAN

Öğrencinin Numarası: 22020088

Anabilim Dalı: Elektrik/Elektronik Mühendisliği

Programı: Elektrik/Elektronik Mühendisliği Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı : Doç. Dr. Ahmet Güngör PAKFİLİZ

Tez Başlığı : Darbeli Radar Sinyallerinin Makine Öğrenmesi Algoritmaları İle Tanımlanması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 68 sayfalık kısmına ilişkin, 03/04/ 2024 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %5'tir. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

"Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını" inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası: .....

ONAY

Tarih: … / … / 2024

Öğrenci Danışmanı Unvan, Adı, Soyadı, İmza:

Doç. Dr. Ahmet Güngör PAKFİLİZ

Bu tezi hayatımın en büyük parçaları olan İrem ve Bal'a ithaf ediyorum.

Mert DEMİRCAN

Ankara - 2024

TEŞEKKÜR

Danışmanım Doç. Dr. Ahmet Güngör PAKFİLİZ'e yüksek lisans eğitimim boyunca ve özellikle tez çalışmaları sürecinde bana olan desteği ve rehberliği için sonsuz teşekkürlerimi ve saygılarımı sunarım.

Ayrıca tez çalışmalarıma verdikleri geribildirimler ile çalışmamın olgunlaşmasına katkılarından dolayı tez jüri üyesi hocalarım Prof. Dr. Sıtkı Çağdaş İNAM ve Dr. Öğr. Üyesi Ahmet ÖZDİL'e teşekkür ederim.

Tüm hayatım boyunca desteklerini esirgemeyen aileme sonsuz teşekkürlerimi sunuyorum.

Son olarak beni her konuda destekleyen, bu yorucu süreçte her zaman yanımda olan sevgili eşim İrem ve kızımız Bal'a teşekkürlerimi sunuyorum.

ÖZET

Mert DEMİRCAN

DARBELİ RADAR SİNYALLERİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE TANIMLANMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik/Elektronik Mühendisliği Anabilim Dalı

2024

Bu tezde radar ikaz alıcılarında radar tanımlama işlemi için makine öğrenmesi yöntemlerinin kullanılması amaçlanmıştır. Bilinen radarların darbeli sinyalleri kullanılarak kapsamlı bir tehdit kütüphanesi oluşturulmuş ve parametre çıkarımı sonrası elde edilen sinyal frekansı, sinyal genişliği, sinyal tekrarlama frekansı ve hüzme genişliği parametreleri ile darbe tanımlayıcı kelimeler oluşturulmuştur. Radar ikaz alıcıların ön programlama fazının optimize edilmesi amacıyla makine öğrenmesi algoritmalarında testler gerçekleştirilmiş ve algoritmaların performansları birbirleriyle ve geleneksel algoritmalarla karşılaştırılmıştır. Probleme uygun olduğu değerlendirilen 5 adet makine öğrenmesi algoritması belirlenmiş ve bu algoritmalar ile modeller oluşturulmuştur. K-en Yakın Komşular, Karar Ağacı, Topluluk Yöntemleri, Destek Vektör Makineler ve Yapay Sinir Ağları algoritmalarındaki ön testler ile hedeflenen %95'in üzerinde öğrenme doğruluğu seviyelerine ulaşmıştır. Hazırlanan tehdit kütüphanesi ile yapılan muharebe ortamı simülasyonlarında %98'in üzerinde test doğruluğu elde edilmiştir. Tamamlanan simülasyon sonuçlarında elde edilen makine öğrenmesi algoritmalarının geleneksel algoritmalara göre hız ve doğruluk açısından güçlü yönleri değerlendirilmiştir.

ANAHTAR KELİMELER: Radar İkaz Alıcısı, Makine Öğrenmesi, Radar Vericisi Tanımlanması

ABSTRACT

Mert DEMİRCAN

IDENTIFICATION OF PULSED RADAR SIGNALS USING MACHINE LEARNING ALGORITHMS

Başkent University Institute of Science

Department of Electrical and Electronics Engineering

2024

This thesis aims to use machine learning methods for radar identification in radar warning receivers. A comprehensive threat library was created using pulsed signals of known radars and pulse descriptor words were created with the signal frequency, signal width, signal repetition frequency and beamwidth parameters obtained after parameter extraction. To optimize the pre-programming phase of the radar warning receivers, machine learning algorithms were evaluated, and their performances were compared with each other and with conventional algorithms. Five machine learning algorithms were identified as suitable for the problem and models were created with these algorithms. The preliminary tests on K-Nearest Neighbors, Decision Tree, Ensemble Methods, Support Vector Machines and Artificial Neural Networks algorithms achieved learning accuracy levels above the targeted 95%. In combat environment simulations with the prepared threat library, test accuracy of over 98% was achieved. The strengths of the machine learning algorithms obtained from the completed simulation results in terms of speed and accuracy compared to traditional algorithms are evaluated.

KEYWORDS: Radar Warning Receiver, Machine Learning, Emitter Identification

İÇİNDEKİLER

TEŞEKKÜR i

ÖZET ii

ABSTRACT iii

İÇİNDEKİLER iv

TABLOLAR LİSTESİ vii

ŞEKİLLER LİSTESİ viii

SİMGELER VE KISALTMALAR LİSTESİ x

1. GİRİŞ 1

1.1. Motivasyon 2

1.2. Katkılar ve Kazanımlar 4

1.3. Kapsam ve Yöntem 5

2. TEMEL KAVRAMLAR VE TEKNİKLER 7

2.1. Elektronik Taarruz Sistemleri 9

2.2. Elektronik Korunma Sistemleri 10

2.3. Elektronik Destek Sistemleri 10

2.4. Radar İkaz Alıcısı 11

2.5. Radar Alıcıları 13

2.5.1. Sayısal Alıcı 13

2.5.2. Süperheterodin Alıcı 14

2.5.3. Kristal Video Alıcısı 15

2.6. Radar Parametreleri 15

2.7. Radarların Tanımlanması 16

2.7.1. Destek Vektör Makineleri Algoritmaları 18

2.7.2. K-En Yakın Komşu Algoritmaları 20

2.7.3. Karar Ağacı Algoritmaları 21

2.7.4. Yapay Sinir Ağları Algoritmaları 22

2.7.5. Topluluk Yöntemleri Algoritmaları 23
3. RADAR SİNYAL KÜTÜPHANESİ 25
3.1. Erken Uyarı ve Hava Gözetleme Radarları 26
3.2. Hava Savunma ve Atış Kontrol Radarları 27
3.3. Hava Platformu Radarları 29
3.4. Radar Sinyal Kütüphanesinin Oluşturulması 31
4. MAKİNE ÖĞRENMESİ ALGORİTMALARININ EĞİTİLMESİ 32
4.1. Model Girdilerinin Hazırlanması 32
4.2. Model Parametrelerinin Belirlenmesi 33
4.3. Modellerin Oluşturulması 34
4.3.1. K-En Yakın Komşular Algoritma Modelinin Optimizasyon Sonuçları 37
4.3.2. Yapay Sinir Ağları Modelinin Optimizasyon Sonuçları 39
4.3.3. Topluluk Yöntemleri Algoritma Modelinin Optimizasyon Sonuçları 42
4.3.4. Destek Vektör Makineleri Modelinin Optimizasyon Sonuçları 44
4.3.5. Karar Ağacı Modelinin Optimizasyon Sonuçları 46
4.4. Final Modellerin Test Edilmesi 48
4.4.1. K-En Yakın Komşular Algoritma Modelinin Test Sonuçları 49
4.4.2. Yapay Sinir Ağları Algoritma Modelinin Test Sonuçları 49
4.4.3. Topluluk Yöntemleri Algoritma Modelinin Test Sonuçları 50
4.4.4. Destek Vektör Makineleri Algoritma Modelinin Test Sonuçları 51
4.4.5. Karar Ağacı Algoritma Modelinin Test Sonuçları 52
5. MAKİNE ÖĞRENMESİ MODELLERİNİN UYGULANMASI 54
5.1. Simülasyon Algoritması 54
5.2. Simülasyon Senaryoları 55
5.2.1. Senaryo 1 56
5.2.2. Senaryo 2 56
5.2.3. Senaryo 3 57

5.2.4. Senaryo 4 ..... **57**

5.2.5. Senaryo 5 ..... **58**

5.2.6. Senaryo 6 ..... **58**

5.3. Simülasyon Senaryolarının Uygulanması **58**

6. SİMÜLASYONDA SENARYOLARIN UYGULANMASI **59**

6.1. Senaryo 1'in Uygulanması **59**

6.2. Senaryo 2'nin Uygulanması **60**

6.3. Senaryo 3'ün Uygulanması **61**

6.4. Senaryo 4'ün Uygulanması **62**

6.5. Senaryo 5'in Uygulanması **63**

6.6. Senaryo 6'nın Uygulanması **64**

6.7. Algoritma Modellerinin Karşılaştırılması **65**

7. DEĞERLENDİRMELER VE SONUÇ **67**

KAYNAKLAR **69**

TABLOLAR LİSTESİ

Sayfa

Tablo 2.1 Sinyal Parametrelerinin Ayrıştırma ve Tanımlamada Ayırt Edicilik Seviyeleri 16

Tablo 3.1 Radar görevlerine göre frekans aralıkları 25

Tablo 3.2 Erken Uyarı Radarları Parametreleri 27

Tablo 3.3 Hava Savunma ve Atış Kontrol Radarları Parametreleri 29

Tablo 3.4 Hava Platformu Radarları Parametreleri 31

Tablo 5.1 Senaryo 1-2-3 Örnek Radar Parametreleri 56

Tablo 5.2 Senaryo 4-5-6 Örnek Radar Parametreleri 57

Tablo 6.1 Senaryo 1 Sonuçları 60

Tablo 6.2 Senaryo 2 Sonuçları 61

Tablo 6.3 Senaryo 3 Sonuçları 62

Tablo 6.4 Senaryo 4 Sonuçları 63

Tablo 6.5 Senaryo 5 Sonuçları 64

Tablo 6.6 Senaryo 6 Sonuçları 65

Tablo 6.7 Doğru Tanımlanan Radar Sayısı Kriterinin Yüzdelik Sonuçları 66

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1 Normal ve CHIRP Uygulanmış Radar Sinyali Darbeleri [12] 8

Şekil 2.2 Elektronik Harp Sınıfları 9

Şekil 2.3 Radar İkaz Alıcısı Fonksiyonel Diyagramı [19] 12

Şekil 2.4 Radar İkaz Alıcısı Sisteminin Gösterge Ekranı [21] 13

Şekil 2.5 Sayısal Alıcı Fonksiyonel Blok Diyagramı [22] 14

Şekil 2.6 Süperheterodin Alıcı Fonksiyonel Diyagramı [23] 15

Şekil 2.7 4 Kanallı Kristal Video Alıcısı Fonksiyonel Blok Diyagramı [24] 15

Şekil 2.8 Radar tanımlama işlemi fonksiyonel blok gösterimi 18

Şekil 2.9 Destek Vektör Makineleri Hiper düzlem Yerleşimi 19

Şekil 2.10 k-En Yakın Komşular Sınıflandırma Örneği 21

Şekil 2.11 Yapay Sinir Ağları Katmanları [42] 23

Şekil 3.1 AN/TPS-63 Kısa/Orta Menzilli Radar Sistemi 26

Şekil 3.2 AN/MPQ-53 PATRIOT Füze Güdüm Radarı 28

Şekil 3.3 F-16 AESA Burun Radarı 30

Şekil 4.1 Tehdit kütüphanesinin model girdisi olarak tanımlanması 32

Şekil 4.2 5 Katlı Çapraz Katlama Yöntemi [48] 33

Şekil 4.3 Classification Learner optimizasyon parametreleri 34

Şekil 4.4 KNN algoritması ile oluşturulan modelin eğitim sonuçları 35

Şekil 4.5 KNN algoritması ile oluşturulan ve optimize edilen modelin eğitim sonuçları 36

Şekil 4.6 YSA, Topluluk Yöntemi, DVM ve Karar Ağacı Öğrenme Modelleri 37

Şekil 4.7 K-En Yakın Komşular optimizasyon grafiği 38

Şekil 4.8 K-En Yakın Komşular Modeli Geçerleme Karıştırma Matrisi 39

Şekil 4.9 Yapay sinir ağları optimizasyon grafiği 40

Şekil 4.10 Yapay Sinir Ağları Modeli Geçerleme Karıştırma Matrisi 42

Şekil 4.11 Topluluk Yöntemleri optimizasyon grafiği 43

Şekil 4.12 Topluluk Yöntemleri Modeli Geçerleme Karıştırma Matrisi 44

Şekil 4.13 Destek Vektör Makineleri optimizasyon grafiği 45

Şekil 4.14 Destek Vektör Makineleri Modeli Geçerleme Karıştırma Matrisi 46

Şekil 4.15 Karar Ağacı optimizasyon grafiği 47

Şekil 4.16 Karar Ağacı Modeli Geçerleme Karıştırma Matrisi 48

Şekil 4.17 K-En Yakın Komşular Algoritma Modelinin Test Karıştırma Matrisi 49

Şekil 4.18 Yapay Sinir Ağları Algoritma Modelinin Test Karıştırma Matrisi 50

Şekil 4.19 Topluluk Yöntemleri Algoritma Modelinin Test Karıştırma Matrisi 51

Şekil 4.20 Destek Vektör Makineleri Algoritma Modelinin Test Karıştırma Matrisi 52

Şekil 4.21 Karar Ağacı Algoritma Modelinin Test Karıştırma Matrisi 53

Şekil 5.1 Simülasyon Algoritması Adımları 55

Şekil 5.2 Makine Öğrenmesi Modelinin Simülasyon Ortamına Aktarılması 58

Şekil 6.1 Simülasyon Sonuç Ekranı 59

SİMGELER VE KISALTMALAR LİSTESİ

AAA	Anti Air Artillery
ANN	Artificial Neural Networks
CNN	Convolutional Neural Networks
CHIRP	Compressed High İntensity Radar Pulse
COMINT	Communication Intelligence
ECM	Electronic Counter Measures
ECCM	Electronic Counter-Counter Measures
ELINT	Electronic Intelligence
ESM	Electronic Support Measures
FMCW	Frequency Modulated Continious Wave
HARM	High Speed Anti Radiation Missile
IF	Intermediate Frequency
IFF	Identification Friend or Foe
KCCA	Kernel Canonical Correlation Analysis
KNN	k-Nearest Neigbors
NEXRAD	Next Generation Weather Radar
RİA	Radar İkaz Alıcı
Rx	Receiver
SAM	Surface to Air Missile
SIGINT	Signal Intelligence
SVM	Support Vector Machines
YSA	Yapay Sinir Ağları

1. GİRİŞ

Radar ve elektronik harp teknolojileri 20. yüzyılın ortalarından itibaren muharebe sahalarının kritik bir özelliği haline gelmiştir. Özellikle modern ordular için vazgeçilmez hale gelen bu teknolojiler temel olarak dost unsurların hareketlerini, niyetlerini ve mümkünse de kendilerini gizlemelerini sağlamak amacıyla kullanılmaktadır. Bunların yanında düşmanın dost unsurlara karşı kullanabileceği silahların kabiliyetlerini azaltmak ve engellemek için kullanılmaktadır.

Elektronik harp teknolojileri doğrudan bir silah sistemi olmamasına rağmen kullanıldığı alanlar ve muharebeler göz önüne alındığında düşman unsurlara dolaylı olarak zarar verdiği ve kimi zaman savaşların dengesini etkilediği görülebilmektedir. İkinci Dünya Savaşı'nda karıştırma tekniklerinin kullanılmaya başlanması ve kullanıldığı muharebelerde önemli avantajlar sağladığı bilinmektedir. Aynı yıllarda gece operasyonlarında İngiliz hava kuvvetlerinin Mosquito Night Fighter uçağına gece operasyonlarında avantaj sağlaması için hava platformu radarı entegre edilmiştir.

Radar teknolojisi ve radar güdümlü silahlar, düşman hedeflerini tespit, takip ve imha etme yeteneklerine sahip olduğundan muharebe sahasında kilit özellikler olarak yerini almıştır. Radar güdümlü silah sistemleri de elektronik harp teknolojilerinin kullanılması ve geliştirilmesi ile önemli teknolojik ilerlemeler kaydetmiştir. Radar güdümlü silahların yaygın kullanımı ve RF teknolojilerinin hızlı gelişimi savunma sanayinde ve devletlerin ekipman modernizasyon stratejilerinde önemli kilometre taşları olarak görülmektedir.

Radar güdüm kullanımı, güdüm sistemlerinde yaygın olarak kullanılan bir tür olup, düşmanın elektronik harp ve fiziksel tehditlerine etkin bir şekilde cevap verebilme yeteneği sağlamaktadır. Bu çok önemli bir avantaj olarak değerlendirilmekle birlikte, bu teknolojik gelişmelerin yaygın kullanımı düşmanların elektronik harp teknolojilerini ve yeteneklerini geliştirmelerine de neden olmaktadır. Her elektronik harp tehdidi ilk defa muhabere alanında kullanılıp düşman unsurlar tarafından fark edildiğinde, bu tehdit ile ilgili alınan bilgiler ışığında kendisine karşı yeni bir elektronik karşı tedbir fonksiyonu yaratılmaktadır. Bu fonksiyonları sağlayan her iki aygıtın tasarımcısı da tasarım sırasında birbirlerinden büyük ölçüde etkilenir. Bazı durumlarda ise bir elektronik harp taarruz ekipmanı tasarımcısı, aynı zamanda uygun koruma ekipmanının tasarımcısı da olabilmektedir. Bu süreçte koruma ekipmanlarının fonksiyonlarının da gelişmesine rağmen elektronik harp teknolojisinde kullanılan teknik ve taktiklerin çoğu zaman muharebelerde önemli kayıplar yaşanarak

öğrenildiği görülmektedir. Bu noktada avantaj üretecek en önemli özellik, rakiplerin sunduğu teknolojiden farklı ve üstün özellikleri mümkün olabilecek en erken zamanda ortaya koyabilmektir. Ayrıca elektronik harp teknolojilerinin geliştirilmesi ve kullanılması hususunda, sıcak bir savaş ve muharebe mevzubahis olmasa dahi bu teknolojiler ülkeler tarafından; askeri tatbikatlarda, sınır koruma harekatlarında ve yakın bölgede kullanılan potansiyel yeni teknolojileri tanımlama gibi amaçlar ile sürekli olarak kullanılmaktadır.

Radar güdümlü tehditler, birlikleri devre dışı bırakmak ve etkisiz hale getirmek için kullanılabilir. Örneğin HARM (high-speed anti-radiation missile) tipi füzeler, düşman unsurları radar sinyalleri gönderdiği sürece hedeflerine doğru seyrederler. Bu tür tehditler ile diğer AAA (anti-air artillery) ve SAM (surface-to-air missile) tehditlerine cevap verebilmek için 20. yüzyılın ortalarından sonlarına doğru askeri uçaklara kendini koruma sistemleri entegre edilmeye başlanmıştır. Bu kendini koruma sistemleri, uçakları düşman silah sistemi radarlarına karşı koruyan elektronik karşı tedbir sistemleri içermektedir. Tehditler, teknoloji yarışına paralel olarak sistemin karmaşıklığını artırırken, askeri birliklerin güvenliğinin sağlanması için daha karmaşık ve etkin elektronik harp sistemlerinin geliştirilmesinin gerekliliğini de ortaya koymaktadır.

Elektronik harp teknolojileri, 20. yüzyılda savaşın doğasını kökten değiştirmesinin yanı sıra bir ordunun askeri kabiliyetini önemli ölçüde artıran önemli bir unsurdur. Muharebe sahasında rekabet üstünlüğünü kaybetme riskini düşürmek için de elektronik harp teknolojilerine girdi sağlayabilecek savunma sanayindeki yenilikler ve tehditler yakından takip edilmeli ve bu yeniliklere karşı sürekli yeni stratejiler ve teknolojiler geliştirilmelidir. Bu teknolojik yarış, ülkelerin elektronik harp bağlamında savunma stratejilerini oluşturmaları, güçlendirmeleri ve gelecekteki muharebe alanlarında rakip ülkelerin önünde yer alabilmeleri için sürekli bir çabayı gerektirmektedir.

1.1. Motivasyon

Dost-düşman tanıma sistemi (IFF) radar teknolojileri arasında kritik bir öneme sahiptir. Bu sistemi etkin bir şekilde kullanarak dost unsurun hayatta kalmasına ve görevine devam etmesini sağlamak için öncelikle düşman unsurun tespit edilmesi ve tanımlanması gerekecektir. Aktif bir muharebe sahasında birbirleri ile girişim halinde bulunan radar sinyallerinin yoğunluğu, radar ikaz alıcısı sistemlerinin sinyalleri doğru bir şekilde tanımlaması için zorlayıcı bir ortam yaratır. Bu nedenle, alınan sinyaller radar ikaz alıcısı işlemcisinde parametreleri kullanılarak ayrıştırılmalı, etiketlenmeli ve tanımlanmalıdır. Bu

işlemler radar ikaz alıcısının işlemcisine tanımlanmış olan algoritmalar yardımı ile yapılmaktadır. Sistemin hatasının en aza indirilmesi için bu algoritmaların çok iyi kurgulanması ve sürekli olarak güncel bilgilere göre optimize edilmesi gerekmektedir.

Başka bir radar göndericisinden alınan sinyallerin algılanması, ayrıştırılması, etiketlenmesi ve tanımlanması radar ikaz alıcısı sistemlerinin içerisindeki modüllerde gerçekleştirilir. Bu işlemleri gerçekleştirmek için radar ikaz alıcısı içindeki bir alıcı alt sistemi (Rx) ile alınan sinyaller, sinyal işlemcisinde daha önceden kendisine tanımlanmış olan radar verici kütüphanesi ile karşılaştırır. Ortamda bulunan unsurların tespit edilmesi için öncelikle radar ikaz alıcısında kullanılan bir yöntem olarak sinyaller frekans, sinyal genliği, geliş açısı ve geliş zaman farkı parametreleri kullanılarak ayrıştırılır ve kümeler halinde etiketlenir. Ayrıştırma ve tanımlama işlemlerinin ikisi için de sinyal parametreleri kullanıldığından, bu süreçler büyük ölçüde radar parametrelerinin doğru ölçülmesine bağlıdır. Ayrıca modern radarlar hedef menziline uyum sağlamak gibi amaçlar için farklı çalışma modlarına sahip olduğundan, farklı çalışma modlarında parametreleri kaydedilen radarlar tarafından yayılan tüm sinyallerin radar verici kütüphanesine dahil edilmesi tanımlama sürecinin doğru yürütülmesinde yüksek önem taşır.

Radar vericisi tanımlama anlamında zorlu olarak görülen aktif bir muharebe sahasında, konvansiyonel radar ikaz alıcısı sistemleri karşılaştırma mekanizmalarını kullanırlar. Karşılaştırma çalışması için referans alınacak veriler ön programlama fazında hazırlandığından, bazı durumlarda çok benzer sinyal parametrelerine sahip radarlar ayırt edilememekte ve yanlış verici olarak tanımlanabilmektedir. Çalışmamızın temel motivasyonu, ön programlama aşamasında sinyal parametrelerini kullanarak tanımlama işlemini gerçekleştiren algoritmaları optimize etmek ve böylece yanlış tanımlamaları yüksek oranda önleyebilecek tanımlama algoritma modelleri oluşturmaktır. Bu amaçla, benzer sinyal parametrelerine sahip radarları başarılı bir şekilde tanımlayabilen makine öğrenmesi algoritmaları araştırılmıştır.

Modern radar ikaz alıcısı sistemleri çeşitli verici tanımlama yöntemleri ile geliştirilmiştir. Bu yöntemler içerisinde, birden fazla radarın faaliyet gösterdiği karmaşık sinyal ortamlarının üstesinden gelmek için yeni algoritmalar kullanılmaktadır. Bu gelişmelere karşı; karıştırma ve modülasyon tipleri ve modülasyon yöntemleri de değiştirilmektedir. Çoğu radarda doğrusal frekans modülasyonu, faz kaydırmalı anahtarlama ve frekans kaydırmalı anahtarlama kullanılmaktadır. Bu modülasyon türleri radarlarda aynı

çalışma modunda ve farklı çalışma modlarında kullanılabilmektedir. Bu nedenle de bahsedilen diğer sinyal parametrelerinin aksine, sinyal modülasyon özelliklerinin verici sınıflandırmasında kullanılması uygun değildir [1].

Elektronik harp teknolojileri; hava, deniz ve kara unsurlarının her biri için farklı fiziki mimarilerde veya fonksiyonlarda kullanılsa da genel olarak amaçları benzerdir. Bu tezde sunulan çalışmalar, görevine başladığında çok uzun mesafeler katedip ilk konumundan çok daha farklı bir bölgede görevine devam edebileceği varsayımında bulunulan hava platformlarına yönelik olarak yapılmıştır. Hava platformlarına entegre edilen elektronik harp sistemleri arasında radar ikaz alıcıda kullanılan algoritmalara odaklanılıp, etkin bir radar tanımlaması sağlanması adına makine öğrenmesi algoritmaları kullanılacaktır.

1.2. Katkılar ve Kazanımlar

Radar ikaz alıcısındaki vericilerin tanımlanması, matematiksel modellerin yanı sıra makine öğrenmesi algoritmaları kullanılarak da gerçekleştirilebilir. Hedef tanımlama ve sınıflandırma için konvansiyonel radar sinyal işleme yöntemleri kullanılırken, makine öğrenmesi ve derin öğrenmedeki son gelişmeler radar tanımlama yeteneklerini geliştirme konusunda ilgi uyandırmıştır. Makine öğrenimi, radar verilerinden karmaşık örüntüleri ve özellikleri çıkararak daha hassas ve verimli hedef, hareket, dalga formu ve sinyal tanımlanmasını sağlayabilmektedir. Son yıllarda yapılan çalışmalar, radar uygulamalarında makine öğreniminin etkinliğini göstermiştir. Örneğin, araştırmalar radar dalga formu tanıma ve radar sinyali özellik çıkarımı konularını ele almıştır [2] [3]. Ayrıca, makine öğrenimi meteorolojik radar kullanarak pirometreleri izlemek, denizde dağıtılmış radar sinyallerini sınıflandırmak ve NEXRAD radar verilerini kullanarak kuş tüneklerinin tespitini otomatikleştirmek için kullanılmıştır [4], [5]. Bu çalışmalar, radar sinyal işleme ve tanımlama görevlerinde makine öğreniminin çok yönlülüğünün ve potansiyelinin altını çizmektedir. Bunlara ek olarak makine öğrenimi teknikleri radar sistemlerinde geleneksel hedef tanımlamanın ötesinde çeşitli uygulamalara yayılmıştır. Örneğin, makine öğrenimi radar verileri kullanılarak insan faaliyetlerinin sınıflandırılması, toprak nemi tahmini ve toprak tuzluluğunun haritalanması [6], [7], [8].

Bu araştırma, makine öğrenimi ve radar sistemleri üzerine mevcut literatürü inceleyerek, radar tanımlama için makine öğrenimini kullanmanın ilerlemeleri, zorlukları ve gelecekteki yönleri hakkında öngörüler sunmayı amaçlamaktadır. Mevcut çalışmaların kapsamlı bir analizi sayesinde bu tez, makine öğrenmesi ve radar teknolojisi arasındaki

sinerjilere ilişkin genişleyen bilgi birikimine katkıda bulunacaktır. Çalışmamızın öncelikli amacı ve literatüre katkısı darbeli radar sinyal tanımlama işlemlerini yüksek doğrulukla gerçekleştirebilen bir makine öğrenmesi modeli oluşturmak ve oluşturulan modelin radar ikaz alıcısındaki işlem hacmini azaltmasıdır. Ayrıca, iki farklı tanımlama görevini gerçekleştirmek için farklı makine öğrenmesi algoritmalarını çok işlevli bir model olarak birleştirmek birincil hedeftir.

1.3. Kapsam ve Yöntem

Birden fazla makine öğrenmesi yöntemi kullanılarak vericilerin tespit edilmesinde en etkili yöntem belirlenerek, bu yöntemin radar ikaz alıcısının işlem yükünü azaltan ve halihazırda kullanılan yöntemlere göre daha doğru kararlar veren etkili bir metot olması hedeflenmektedir. Çalışmamızda kullanılmak üzere birçok makine öğrenmesi algoritması araştırılmış, ancak elimizdeki probleme uygulanabilir olarak görülen ve daha sonra test edilerek doğrulanan Destek Vektör Makinesi (SVM), K-En Yakın Komşular (KNN), Karar Ağacı, Topluluk Yöntemleri ve Yapay Sinir Ağları (ANN) algoritmaları kullanılmıştır. Bu algoritmalar ile ilgili detaylar ilerdeki bölümlerde açıklanmıştır.

Bu tezde temel olarak, uçaklardaki radar ikaz alıcı sistemleri tarafından ayrıştırılan darbe radar sinyallerinin makine öğrenmesi algoritmaları ile tanımlanması açıklanacaktır. Kullanılan algoritmalar ile sinyal vericilerini tanımlamak için sinyal parametreleri kullanılıp, bir öğrenme modeli ortaya çıkarılmıştır.

Çalışmamızın ilk bölümünde ayrıştırılmış radar sinyallerinin tanımlanmasında makine öğrenmesi yöntemleri için önceden tanımlanmış bir radar sinyal kütüphanesi oluşturulmuştur. Bu kütüphane ile simülasyonda kullanılacak tüm radar vericileri için daha önce bahsedilen radar parametreleri tanımlanmıştır. Tehdit kütüphanesi oluşturulurken edinilen radar sinyal parametreleri için açık kaynaklardan yararlanılmıştır [9], [10].

İkinci bölümde ise çalışmamıza uygun birçok makine öğrenmesi algoritması ile doğruluk testleri gerçekleştirilmiş ve algoritmaların performansları değerlendirilmiştir. Uygun olduğu değerlendirilen algoritmaların öğrenme modelleri oluşturulmuş ve simülasyonda kullanılmaya hazır hale getirilmiştir.

Çalışmanın son bölümünde ise doğruluk performansları uygun görülen makine öğrenmesi algoritma modelleri, hazırlanan yardımcı simülasyon algoritması tarafından belirlenen radar sinyal sayısı ile karmaşık bir sinyal ortamının simülasyonuna

uygulanacaktır. Farklı radar sinyalleri ile yapılacak deneyler sonrasında doğruluk test sonuçları ve simülasyon sonuçları gösterilerek bu sonuçlar değerlendirilecektir.

2. TEMEL KAVRAMLAR VE TEKNİKLER

Radar, nesneleri tespit etmek ve yerlerini belirlemek için radyo dalgalarını kullanan elektronik bir sistemdir. Radar kelimesi İngilizce "Radio Detection and Ranging"' ifadesinin kısaltması olarak kullanılmaktadır. Meteoroloji, trafik izleme ve savunma gibi çeşitli alanlarda uygulama alanı bulmaktadır. Radarın çalışma prensibi, elektromanyetik enerji darbelerinin ışık hızında bir hedefe doğru iletilmesini içerir. Bu darbeler bir nesneyle karşılaşana kadar uzayda yol alır ve darbeler bir nesneden yansıdığında radar sistemi yansıyan sinyalleri algılar. Bu algılama işlemi radarın çalışmasının temelini oluşturur ve nesnenin konumunun, hızının ve diğer özelliklerinin belirlenmesini sağlar. Radar teknolojisi askeri uygulamalarda gözetleme, hedef belirleme ve tehdit algılama gibi yetenekler sağlar. Askeri radar sistemleri hava sahasını izlemek, füze veya uçak gibi gelen tehditleri tespit etmek ve savunma önlemlerini yönlendirmek için çok önemlidir. Ayrıca, radar teknolojisi, düşman kuvvetlerinin hedef tespiti ve tanımlanması için gerçek zamanlı gözetim yetenekleri sağlayarak askeri istihbarat toplamada hayati bir rol oynamaktadır. Radar sistemlerinin askeri senaryolarda iletişim işlevleriyle bütünleştirilmesi, özellikle elektronik harp uygulamalarında kaynak paylaşımını mümkün kılmakta ve operasyonel verimliliği artırmaktadır.

Farklı radar teknolojileri hedeflerine ulaşmak için çeşitli teknikler kullanırlar. Örneğin Doppler radarı, hareketli bir hedefle karşılaşıldığında gönderilen dalganın frekansının ve fazının değiştiği Doppler etkisine dayalı olarak çalışır. Frekanstaki bu değişim, radar sisteminin hareketi algılamasını sağlayarak hedefin hızı hakkında bilgiler sağlar. Buna ek olarak frekans modülasyonlu sürekli dalga (FMCW) radarı, sürekli dalga iletimi elde etmek için frekans modülasyonu ilkesine dayalı olarak çalışan bir radar teknolojisidir. FMCW radar sistemleri zaman içinde değişen frekanslara sahip sürekli sinyaller yayar ve sinyallerin eşzamanlı olarak gönderilmesine ve alınmasına izin verir. Alınan sinyallerdeki frekans kaymalarını analiz ederek, FMCW radarı hedeflerin menzilini ve hızını doğru bir şekilde belirleyebilir.

Bu tezde kullanılan darbe radar teknolojisi, savunma sistemlerinde gelişmiş duyarlılık ve menzil çözünürlüğü sağlayan çok önemli bir bileşendir. Darbe sıkıştırma radarı gibi eş evreli radarlar, elektronik karıştırmayı azaltmak için eş evreli işlem kazancından yararlanır ve bu tür tehditlere karşı savunma için eş evreli karıştırma teknolojisini gerektirir [11]. Ayrıca radar sistemlerinde yaygın olarak kullanılan doğrusal CHIRP dalga biçimleri, darbe

sıkıştırma teknolojisi sayesinde menzil çözünürlüğünü ve sinyal-gürültü oranını artırmaktadır. CHIRP sinyalleri gibi darbe sıkıştırma radar dalga biçimlerinin kullanımı modern radar sistemlerinde yaygındır. Şekil 2.1'de CHIRP yöntemi ile sıkıştırılmış sinyal darbesi grafiği gösterilmiştir.

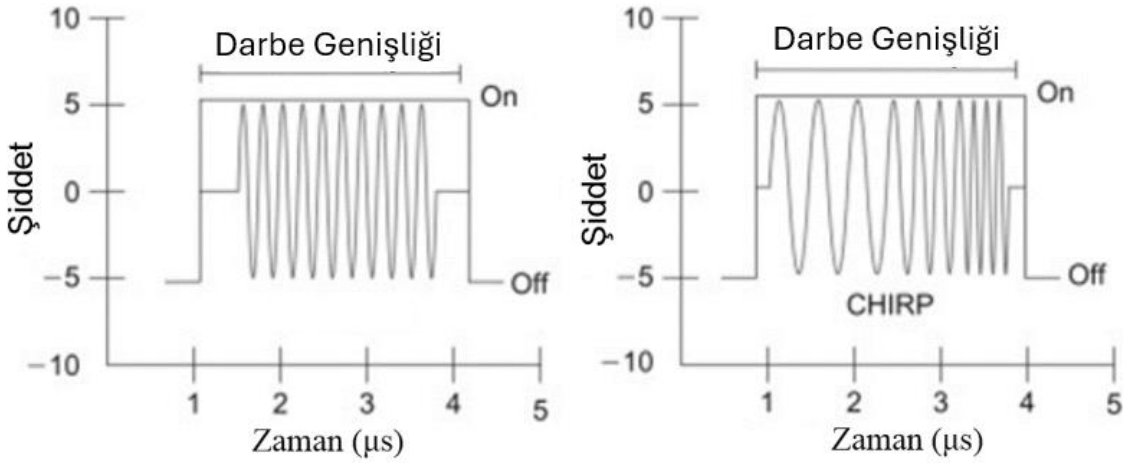

Şekil 2.1 Normal ve CHIRP Uygulanmış Radar Sinyali Darbeleri [12]

Elektronik Harp modern askeri operasyonların kritik bir bileşenidir ve elektromanyetik spektrum üzerinde kontrol sağlamayı amaçlayan çok çeşitli strateji ve teknolojileri kapsar. Grant ve Collins'in sunduğu görüş elektronik harbe giriş niteliğinde bir genel bakış sunmakta ve bu teknolojinin üç ana alt kümesini tanımlamaktadır; Elektronik Destek Tedbirleri (ESM), Elektronik Karşı Tedbirler (ECM) ve Elektronik Karşı-Karşı Tedbirler (ECCM) [13]. Elektronik harp bileşenlerine ilişkin bu temel anlayış, elektronik harp taktikleri ve teknolojilerine ilişkin daha ileri düzeydeki tartışmaların temelini oluşturmaktadır. Ancak 1990'lı yıllarda teknolojik gelişmeler ve değişen askeri ihtiyaçlara göre elektronik harp bileşenlerinin tanımı değiştirilmiş, yine üç sınıf ile tanımlanmıştır. Bunlar; Elektronik Destek, Elektronik Taarruz ve Elektronik Korunma olarak kabul görmüştür [14][15]. Şekil 2.2'de elektronik harp sınıfları ve bu sınıflar altında değerlendirilen sistemler görülmektedir.

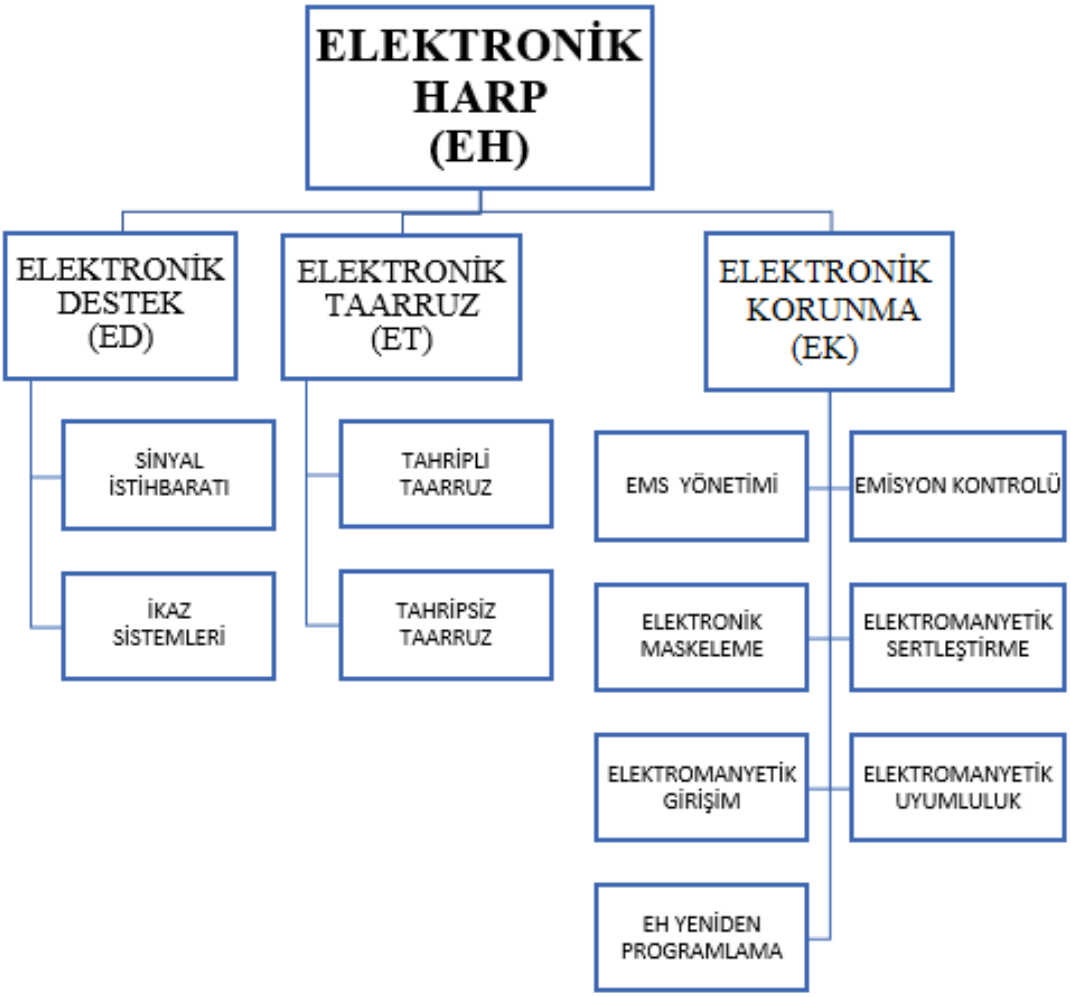

Şekil 2.2 Elektronik Harp Sınıfları

2.1. Elektronik Taarruz Sistemleri

Elektronik taarruz sistemleri entegre olduğu platforma tehdit olan unsurların elektronik harp kabiliyetlerini engellemek amacıyla kullanılır. Karşıdaki düşman unsuru fiziki olarak tahrip etmeyen ancak fonksiyonel kabiliyetlerini kısıtlayan elektronik taarruz tipleri işlevsel imha (soft kill) olarak sınıflandırılır. Bu taarruz tipleri düşmanın elektromanyetik spektrumu kullanmasını kısıtlayıp ve mümkünse de engelleyerek operasyon sahasında kullanıldığı platformun tespit edilmesi veya takip edilmesini zorlaştırmaktadır. İşlevsel imha taarruzlarından biri olan karıştırma yönteminde düşman unsurların radarlarını satüre etmeyi hedefleyerek gürültü ile karıştırma uygulanmaktadır. Aldatma yönteminde ise karıştırma tekniklerinden faydalanılarak mesafe aldatması, hız aldatması, açı aldatması, sahte hedef aldatması gibi yöntemler kullanılmaktadır. Bu yöntemler kullanılırken temel amaç platformun gerçek yerinin gizlenmesi, hedef olarak tespit edilememesi ve bu sayede

fonksiyonel kabiliyetlerinin devam etmesidir. Fiziksel imha (hard kill) taarruzları ise tehdit olarak değerlendirilen unsurun işlevini yerine getiremeyecek şekilde hasar verilmesi veya tamamen imha edilmesi ile gerçekleştirilmektedir. Anti-radyasyon silahları (örneğin HARM) ve yönlendirilmiş enerji silahları fiziksel imha kapsamında kullanılmaktadır. 1990'lı yıllar öncesinde kullanılan eski sınıflandırma sisteminde elektronik harp kapsamında olmayan bu sistemler, yeni sınıflandırmada elektronik taarruz sistemleri arasında tanımlanmaya başlanmıştır.

2.2. Elektronik Korunma Sistemleri

Elektronik korunma sistemleri diğer elektronik harp sistemlerinin müdahalelerinden korunmak amacıyla kullanılan sistemlerdir. Kullanıldığı platformun elektronik taarruz ile fonksiyon engelleme veya kabiliyet azaltma aksiyonlarına karşı hem aktif hem de pasif önlem alınmasını sağlar. Örneğin karıştırma sistemlerinin etkisiz kılınması için yaygın olarak frekans çevikliği yöntemleri kullanılmaktadır. Frekans çevikliği yönteminde, yayın yapan verici yaydığı sinyallerin frekansını, kullanabildiği frekans bandında rastgele olarak değiştirmesi ve bu sayede karıştırma sisteminin sinyal frekansını kaçırması ile etkisizleştirilmesi sağlanır. Ayrıca platformdan yayılan sinyalin yan hüzmelerine kilitlenen radar güdümlü füzeler karşı da yan demet kesici veya yan demet azaltıcı önlemler alınmaktadır. Ayrıca güdümlü füzelere karşı Chaff/flare ile aldatma yöntemi kullanılarak da koruma sağlayan sistemler bulunmaktadır.

Korunma sistemlerinde yapısal önlemler de gözlemlenmektedir. Özellikle hayalet uçaklar olarak adlandırılan hava platformlarında radar kesit alanının küçültülmesi ve gövdeye radar emici malzeme kaplaması uygulanması yapısal önlemler olarak değerlendirilmektedir. Bu önlemler tarama görevi yürüten bir başka radarın, uçaktan alacağı dönüş sinyalinin gücünü düşürmekte ve tespit edilmeyi zorlaştırmaktadır.

2.3. Elektronik Destek Sistemleri

Elektronik destek sistemleri temel olarak askeri unsurların tespit edilmesine yönelik fonksiyonları sağlamaktadır. Sinyallerin alınması, yönlerinin bulunması, uzaklıklarının belirlenmesi ve tanımlanması işlemleri bu sistemler tarafından gerçekleştirilir. Radar ikaz sistemleri dışında elektronik destek sistemleri, aldığı ve analiz ettiği sinyallere göre de sistemler iki farklı şekilde sınıflandırılır. Elektronik istihbarat (ELINT) sistemleri olarak sınıflandırılan kısım; atış kontrol, güdüm ve erken uyarı radarlarından gelen sinyallerin

alınması ve analiz edilmesinde kullanılır. İletişim istihbaratı (COMINT) sistemleri ise veri bağlantısı yolu ile iletilen ses ve görüntü gibi paketlerin tespit ve elde edilip, dost unsurlar tarafından analiz edilmesinde kullanılır. Bu iki sınıflandırmanın birlikte kullanılması ile de sinyal istihbaratı (SIGINT) olarak tanımlanmaktadır. Sinyal istihbaratı ile elde edilen sinyal parametreleri de analiz edilip radar ikaz alıcısı sistemlerinin ön programlama aşamasında kullanılır.

Radar tanımlama işleminin ön programlama aşaması, radar sistemlerinin çeşitli radar sinyallerini algılamak ve sınıflandırmak için önceden tanımlanmış parametreler ve algoritmalarla yapılandırılmasını içerir. Bu aşama, elektronik destek sistemleri tarafından yakalanan tanımlanmış radar tehditlerine karşı önceden programlanmış karıştırma tekniklerini kullanan elektronik taarruz sistemleri için çok önemlidir [16]. Belirli verici tanımlama algoritmaları, parametre öğrenme tekniklerini kullanarak sıfır örnek senaryoları da dahil olmak üzere çeşitli koşullar altında radar sinyallerini tanımak için gereklidir [17]. Örneğin Dudczyk'in yaptığı çalışmada büyük veri kümelerine dayalı radar emisyon kaynağı tanımlama için hiyerarşik aglomeratif kümeleme yöntemleri kullanılmakta ve böylece radar tanımlama süreçlerinin verimliliği artırılmaktadır [18]. Ayrıca radar sinyali parametre çıkarımı ile ilgili olarak, modülasyon özelliklerinin çıkarılması radar sinyalinin tanımlanması için çok önemli olduğu ortaya koyulmuştur [3]. Özel verici tanımlama algoritmaları, dağınıklık dağılımı tanımlama yöntemleri ve hiyerarşik kümeleme gibi teknikler radar sinyal tanımlama süreçlerinin geliştirilmesinde hayati rol oynar.

Ön programlama aşaması elektronik istihbarat sistemleri ile toplanmış ve tanımlanmış radar sinyallerinin analiz edildiği bir elektronik harp destek merkezinde gerçekleştirilir. Belirli bölgeler ve görevler için platformlara görev öncesi yüklenmek üzere kütüphaneler burada oluşturulup radarlara ilişkin darbe tanımlayıcı kelimeler sürekli olarak optimize edilmeye ve güncellenmeye devam edilir.

2.4. Radar İkaz Alıcısı

Radar ikaz alıcısı, elektronik harp sistemlerinde potansiyel tehditler tarafından yayılan radar sinyallerini tespit etmek ve tanımlamak için tasarlanmış kritik bir bileşendir. Radar ikaz alıcısı sistemleri kullanıldığı platformun bulunduğu ortamda tehdit olarak değerlendirilen unsurların bulunduğunu, tespit işlemi gerçekleştiği anda kullanıcıya bildirmektedir. Kullanıcıya bildirilen bilgiler genellikle tehdidin yönü, uzaklığı ve tanımıdır. Bu bilgileri sağlarken radarın alıcı kısmı tarafından alınan sinyaller ile sistemine daha önce

tanımlanmış olan sinyalleri karşılaştırarak çıktısını vermektedir. Radar ikaz alıcını temel çalışma akışı, öncelikle alıcının ortamdaki sinyalleri yakalaması ile başlar. Alınan sinyallerin parametreleri belirlenip, bu sinyaller gruplanır. Gruplanan sinyaller sinyal kütüphanesi ile karşılaştırılarak, radar ikaz alıcısının işlemcisinde yüklü olan algoritma ile tanımlanır. Tanımlanan radarların tehdit olup olmadığı değerlendirildikten sonra, tehdit seviyesine uygun olarak alınacak aksiyon için bilgi iletilir. Radar ikaz alıcının bu jenerik fonksiyonel çalışma akışı Şekil 2.3'te de gösterilmiştir.

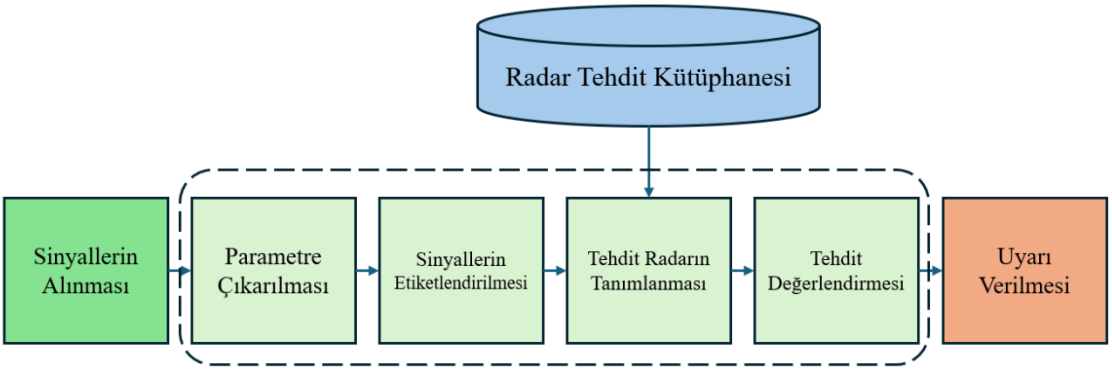

Şekil 2.3 Radar İkaz Alıcısı Fonksiyonel Diyagramı [19]

Tehdit kütüphanesi olarak isimlendirilen sinyal parametrelerinin tanımlandığı bir veri tabanı 2.3 bölümünde de bahsedildiği gibi platform göreve çıkmadan önce üzerindeki radar ikaz alıcısına yüklenir. Bu işlemde kullanılan kütüphane göreve çıkılan bölge ile değişken olmakla birlikte, bölgede olması beklenen ve bilinen platformların radar sinyal parametrelerinin darbe tanımlayıcı kelimelerini içermektedir. Sabit kütüphane kullanımının tercih edilmemesinin de sebepleri arasında en önemli olarak görüleni de işlem süresinin uzayacak olması nedeniyle tehdidin tespit edilebilecek en erken andan daha geç tespit edilmesi nedeni ile platform ve kullanıcı için tehlikeli veya ölümcül sayılabilecek durumların önüne geçmektir. Tehdit kütüphanelerinde genellikle bir önceliklendirme yapısı da bulunmaktadır. Bu önceliklendirme yapısı, platformun otomatik ya da manuel olarak alacağı tedbirlerin öncelikle hangi tehdide göre alınması gerektiği konusunda karşı tedbir sistemine girdi sağlamaktadır [20]. Örneğin, bir hava platformunda bulunan radar ikaz alıcı ortamda bulunan hava gözetleme radarından önce kendi platformunu takip eden bir silah güdüm radarını tespit edip karşı tedbir sistemine bilgi vermek üzere programlanmaktadır. Bunun da sebebi çoğu askeri sistemde olduğu gibi önceliğin görevin devamını sağlamak ve bunu da ancak kendi platformunun bekasını sağlayarak gerçekleştirebileceği fikridir. Radar ikaz alıcı

gösterge ekranında Şekil 2.4'te gösterildiği gibi farklı semboller ve renkler ile pilota tehdit çeşidi, uzaklığı ve yönü ile ilgili bilgi verilmektedir.

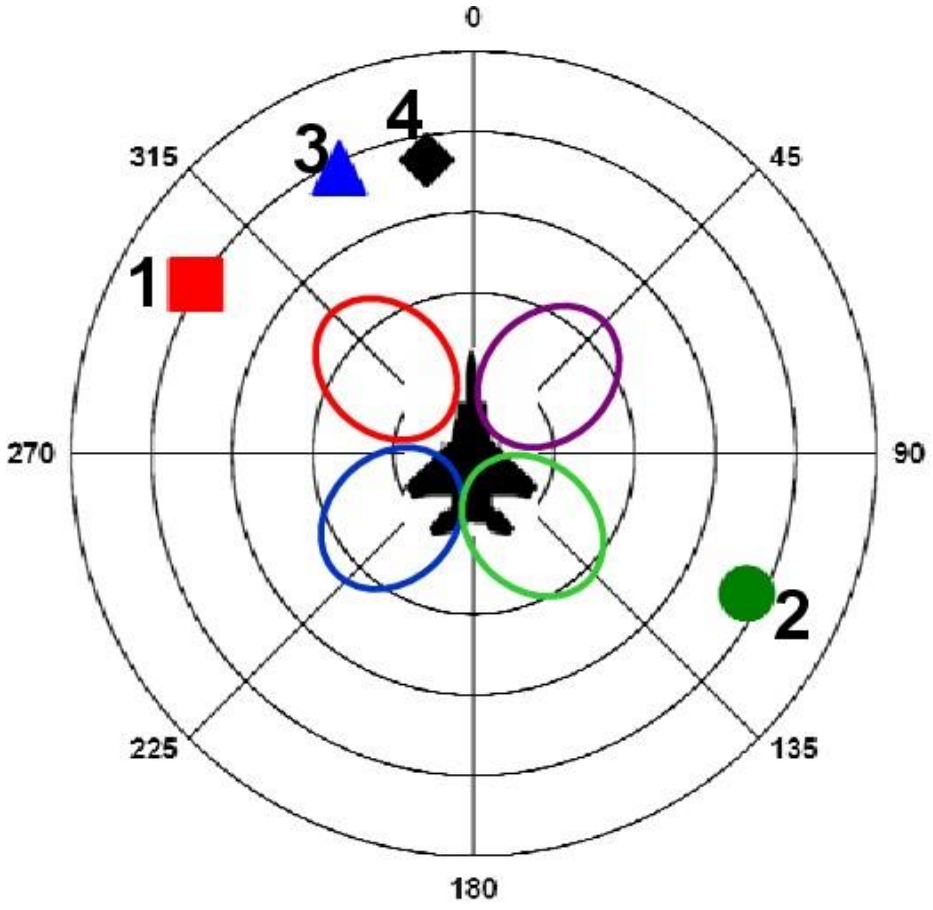

Şekil 2.4 Radar İkaz Alıcısı Sisteminin Gösterge Ekranı [21]

2.5. Radar Alıcıları

Radar ikaz alıcı sisteminin önemli bir parçası olan alıcıların (Rx) kullanılan birçok türü bulunmaktadır. Bu alıcı çeşitleri farklı fonksiyonel özelliklerine göre hibrit veya tekil olarak kullanılabilmektedir.

2.5.1. Sayısal Alıcı

Sayısal alıcılar, radar ikaz alıcısında yapılacak işlemleri bilgisayar ortamında yapmak üzere sinyalleri sayısal forma dönüştürür. Burada yapılan işlemler (demodülasyon, filtreleme vb.) yazılım tarafından simüle edilerek gerçekleştirilebilmektedir. Bulunduğu sistemi etkileyen en önemli özelliği de bu işlemleri gerçekleştirmek için ihtiyaç duyulan işlemcinin boyut ve ağırlık dezavantajını bulunduğu platforma yansıtması ve buna paralel olarak donanım kısıtlarından dolayı kullanıldığı alandaki tüm frekans spektrumunun

tamamını kapsayacak şekilde çalışmamasıdır. Bu nedenle ağırlık ve hacim konusunun diğer platformlara göre daha değerli görüldüğü hava platformlarında kullanımı yaygın değildir.

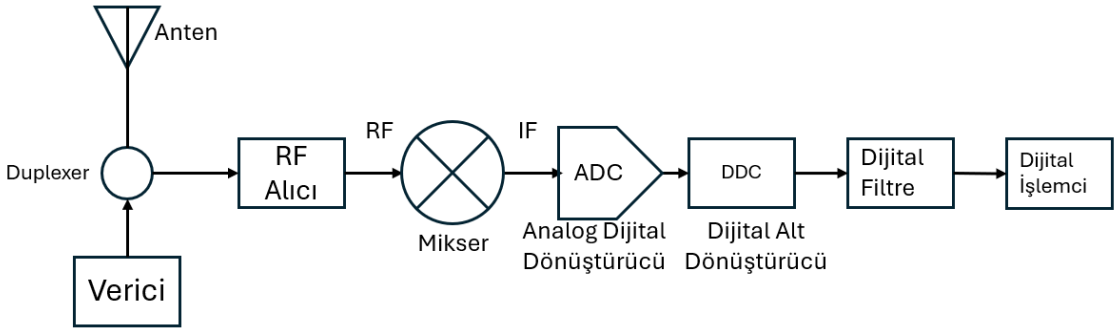

Şekil 2.5 Sayısal Alıcı Fonksiyonel Blok Diyagramı [22]

2.5.2. Süperheterodin Alıcı

Süperheterodin alıcı, radyo frekansı sistemlerinde üstün seçiciliği, hassasiyeti ve frekans kararlılığıyla bilinen temel bir bileşendir. Bir süperheterodin alıcının mimarisinde tipik olarak, gelen sinyalleri daha ileri işlemler için sabit bir ara frekansa (IF) dönüştürmek amacıyla frekans dönüştürme komponentleri bulunmaktadır. Bu sistem, sinyallerin verimli bir şekilde filtrelenmesine, yükseltilmesine ve demodüle edilmesine olanak tanıyarak radyo frekansı iletimlerinin hassas bir şekilde alınmasını ve analiz edilmesini sağlar. Radar ve iletişim sistemleri bağlamında, süperheterodin alıcı, gelen sinyallerin algılanması ve işlenmesinde çok önemli bir rol oynar. Alıcının gelen sinyalleri standart bir IF frekansına dönüştürme yeteneği, sinyalleri işleme ve demodülasyonu kolaylaştırarak genel sistem verimliliğini artırır. Ayrıca, süperheterodin alıcıların frekans modülasyonlu sürekli dalga (FMCW) radarı gibi radar uygulamalarında kullanılması, hedef tespitinde yüksek çözünürlük ve doğruluk elde etmedeki etkinliklerini göstermektedir. Genel olarak, süperheterodin alıcının çok yönlülüğü, seçiciliği ve kararlılığı, onu modern radyo frekansı sistemlerinde önemli bir alıcı mimarisi haline getirmekte ve çeşitli uygulamalarda verimli sinyal alımı, işleme ve analizine olanak sağlamaktadır.

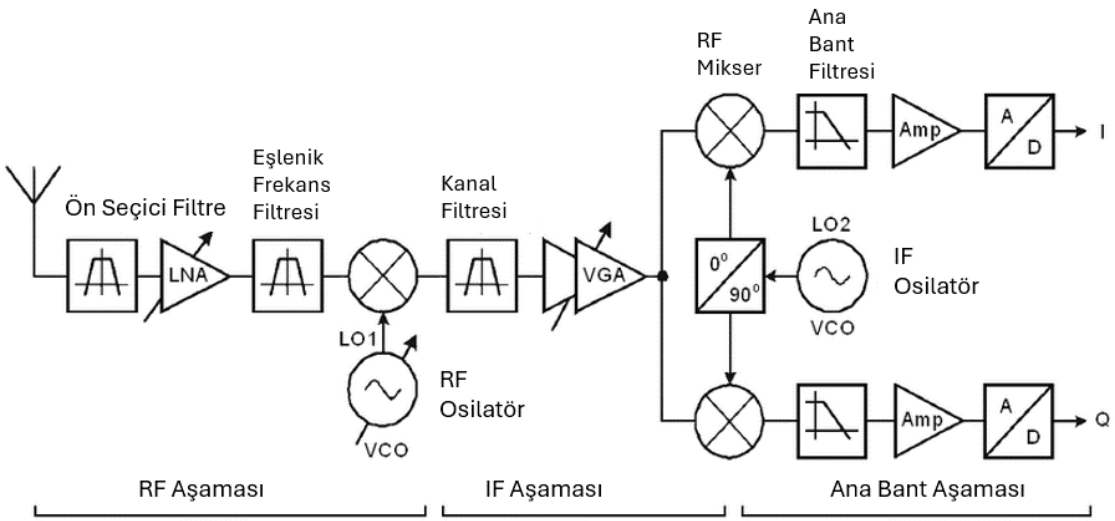

Şekil 2.6 Süperheterodin Alıcı Fonksiyonel Diyagramı [23]

2.5.3. Kristal Video Alıcısı

Kristal video alıcısı, anten, dedektör ve yükselticiden oluşup, sinyalleri yüksek hassasiyet ve netlikle almak, işlemek ve kodunu çözmek için tasarlanmış, sinyal iletim sistemlerinde çok önemli bir bileşendir. Diğer alıcı sistemlerine göre karmaşıklığı düşük olmasına rağmen yüksek anlık bant genişliği sağlar. Ancak hassasiyet, ölçüm sonuçları için düşük performans gösterir.

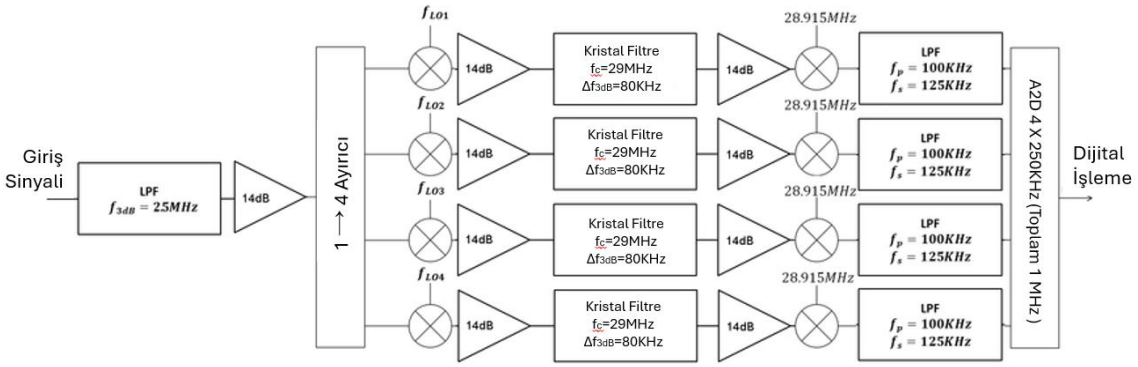

Şekil 2.7 4 Kanallı Kristal Video Alıcısı Fonksiyonel Blok Diyagramı [24]

2.6. Radar Parametreleri

Radarların tanımlanmasında kullanılan radar ikaz alıcı sistemleri, ortamdaki radarların bazı karakteristik sinyal parametrelerini kullanır. Bu parametreler; frekans, darbe genliği,

darbe genişliği, darbe yönü, geliş zamanı, darbe tekrarlama frekansı, anten tarama zamanı, hüzme genişliğidir.

Radar parametreleri kullanılarak yapılan tanımlama işlemlerinde, aynı zamanda alınan radar sinyaller üst üste binerek bir ayrıştırma problemi de yaratırlar. Ayrıştırma işlemi de alınan sinyallerin parametreleri kullanılarak gerçekleştirilir ve tanımlama işlemine ayrıştırılmış radar sinyal setleri gönderilmesi sağlanır. Ayrıştırma ve tanımlama işlemlerinde sinyal parametrelerinin ayırt edicilik seviyeleri farklıdır. Bu nedenle bütün sinyal parametreleri iki problemin çözülme işleminde kullanılmamaktadır. Ayrıştırma ve tanımlama işlemlerinde kullanılan sinyal parametrelerinin elde edilme şekilleri ve ayırt edicilik seviyeleri Tablo 2.1'de verilmiştir [25] [26].

Tablo 2.1 Sinyal Parametrelerinin Ayrıştırma ve Tanımlamada Ayırt Edicilik Seviyeleri

Sinyal Parametresi	**Parametrenin Elde Edilmesi**	**Ayrıştırma İşlemi Ayırt Edicilik**	**Tanımlama İşlemi Ayırt Edicilik**
Frekans	Ölçüm	Yüksek Seviyede	Yüksek Seviyede
Darbe Tekrarlama Frekansı	Alınan veriden türetme	Yüksek Seviyede	Yüksek Seviyede
Dalga Genişliği	Alınan veriden türetme	Yüksek Seviyede	Orta Seviyede
Darbe Genliği	Ölçüm	Orta Seviyede	Düşük Seviyede
Hüzme Genişliği	Alınan veriden türetme	Düşük Seviyede	Yüksek Seviyede
Geliş Yönü/Açısı	Ölçüm	Yüksek Seviyede	Düşük Seviyede
Geliş Zamanı	Ölçüm	Yüksek Seviyede	Düşük Seviyede
Anten Tarama Süresi	Alınan veriden türetme	Düşük Seviyede	Yüksek Seviyede

2.7. Radarların Tanımlanması

Radarların yaydığı sinyallerin karakteristik parametrelerinden tanımlanması işlemi elektronik harp destek sistemlerinin daha önce bahsedildiği gibi hayati bir fonksiyondur. Karmaşık bir sinyal yoğunluğu içeren operasyonel bir ortamda, üst üste binmiş sinyallerin ayrıştırılma aşamasından sonra, sinyal kaynaklarının tanımlanması bu sinyal kaynakları arasında bir tehdit var ise belirlenmesi karşı tedbirlerin belirlenmesi konusunda çok kritiktir. Ortamda aynı anda onlarca sinyal kaynağı bulunabilen durumlarda konvansiyonel

karşılaştırma ile tanımlama sistemlerinin yetersizliği ve yanlış tespitlere açıklığı nedeni ile radarların tanımlanması konusu elektronik harp sistemleri arasında geliştirilmeye ihtiyaç duyulan bir noktadadır.

Bu konuda yapılan çalışmalarda konvansiyonel teknolojiler ve yeni teknolojileri birlikte görebilmekteyiz. Yang ve arkadaşlarının sunduğu yaklaşım, spesifik verici tanımlaması amaçları doğrultusunda radar vericisi tanımlama işlemini gerçekleştirmek için alınan radar sinyallerinin bir koleksiyonunun kullanılmasını içerir [27]. Bu yöntem, sinyal özelliklerine dayalı olarak aynı tip radar vericilerinin farklı kopyaları arasında ayrım yapmaya odaklanır. Çalışmamızda oldukça faydalandığımız kavramları araştıran başka bir araştırmada ise elektronik harp sistemlerinde radar verici sınıflandırmasında evrişimli sinir ağlarının (CNN), radar vericilerini benzersiz özelliklerine göre sınıflandırmadaki rolü vurgulanıp, yapılan simülasyon çalışması neticesinde %97'lere varan radar tanımlama doğruluk oranları sağlanmıştır [28]. Farklı bir çalışmada, radar verici tanımlama zorluklarını ele almak için çekirdek kanonik korelasyon analizinden ve belirsizlik fonksiyonundan yararlanarak, radar vericisi tanımlama için yeni bir hibrit füzyon yöntemi önerilmiştir. Bu yönteme göre belirsizlik fonksiyonunun sıfıra yakın doppler dilimleri kullanılarak iki çekirdek matris hazırlanır ve bu matrisler ile de ayırt edici özellikleri çıkarmak amacıyla KCCA kullanılır. Bu hibrit yöntem ile Shi ve arkadaşları öğrenme hızı ve doğruluk oranı bakımından yüksek verimli bir yöntem olarak sonuç almıştır [29].

Bu tezde simülasyon çalışması öncesi sinyal kütüphanesi oluşturulup, algoritmalar etiketli bir veri seti ile eğitilecektir. Bu nedenle makine öğrenmesi algoritmaları arasından gözetimli öğrenme teknikleri kullanılmıştır. Literatür araştırmaları ve yapılan ön testler sonucu, radar sinyali ile verici tanımlama problemine uygulanabilecek gözetimli öğrenme algoritmaları ve yöntemleri; Destek Vektör Makinesi (Support Vector Machines- SVM), K-En Yakın Komşular (K-Nearest Neighbors- KNN), Karar Ağacı (Decision Tree), Topluluk Yöntemleri (Ensemble Methods) ve Yapay Sinir Ağları (Artificial Neural Networks- ANN) algoritmaları 1.3 bölümünde de bahsedildiği üzere seçilmiştir.

Şekil 2.8'de makine öğrenmesi algoritmaları ile tehdit kütüphanesi kullanılarak radarların tanımlama işleminin hangi adımlar izlenerek yapılacağı fonksiyonel bloklar halinde gösterilmiştir.

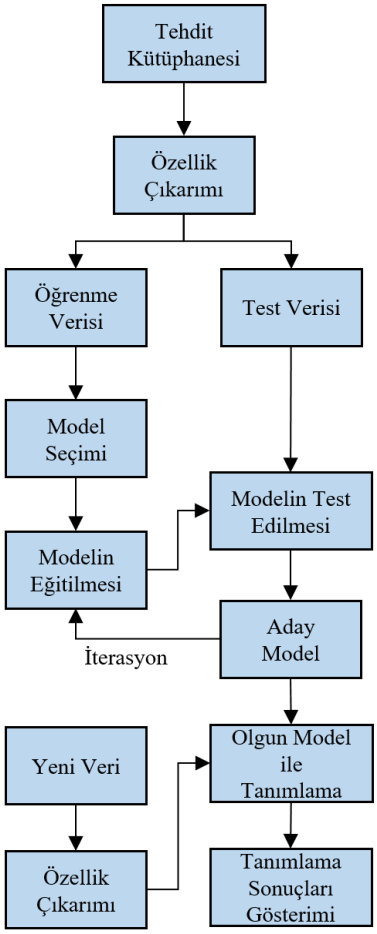

Şekil 2.8 Radar tanımlama işlemi fonksiyonel blok gösterimi

Takip eden bölümlerde simülasyonda kullanılacak olan makine öğrenmesi algoritmaları açıklanmıştır.

2.7.1. Destek Vektör Makineleri Algoritmaları

Destek vektör makineleri (Support Vector Machines), makine öğrenimi, yapay zeka ve örüntü tanıma gibi çeşitli alanlarda yaygın olarak kullanılan çok yönlü ve güçlü bir denetimli öğrenme algoritmaları sınıfıdır. SVM algoritmaları özellikle sınıflandırma görevleri, regresyon ve algılama için etkili olduğu görülmektedir [30]. SVM algoritmalarının arkasındaki temel kavram, geometrik aralığı en üst düzeye çıkarırken eğitim veri kümesindeki farklı sınıfları doğru bir şekilde ayırabilen en uygun hiper düzlemi bulmaktır. Bu hiper düzlemin yeri, hiper düzlem ile destek vektörleri olarak adlandırılan en yakın veri noktaları arasındaki mesafeyi maksimize edecek şekilde belirlenir [31]. SVM algoritmaları hem doğrusal hem de doğrusal olmayan sınıflandırma problemlerini verimli bir şekilde ele alma yetenekleriyle bilinir. Bunu, çekirdek yöntemi (kernel trick) olarak bilinen bir teknik

kullanarak girdi verilerini yüksek boyutlu özellik uzaylarına dolaylı olarak eşleyerek sağlarlar [32]. Bu, SVM algoritmalarının orijinal parametre uzayında doğrusal olarak ayrılamayan veri noktalarını doğru bir şekilde sınıflandırabilen doğrusal olmayan ayırt edici sınıflandırıcılar oluşturmasına olanak tanır [33].

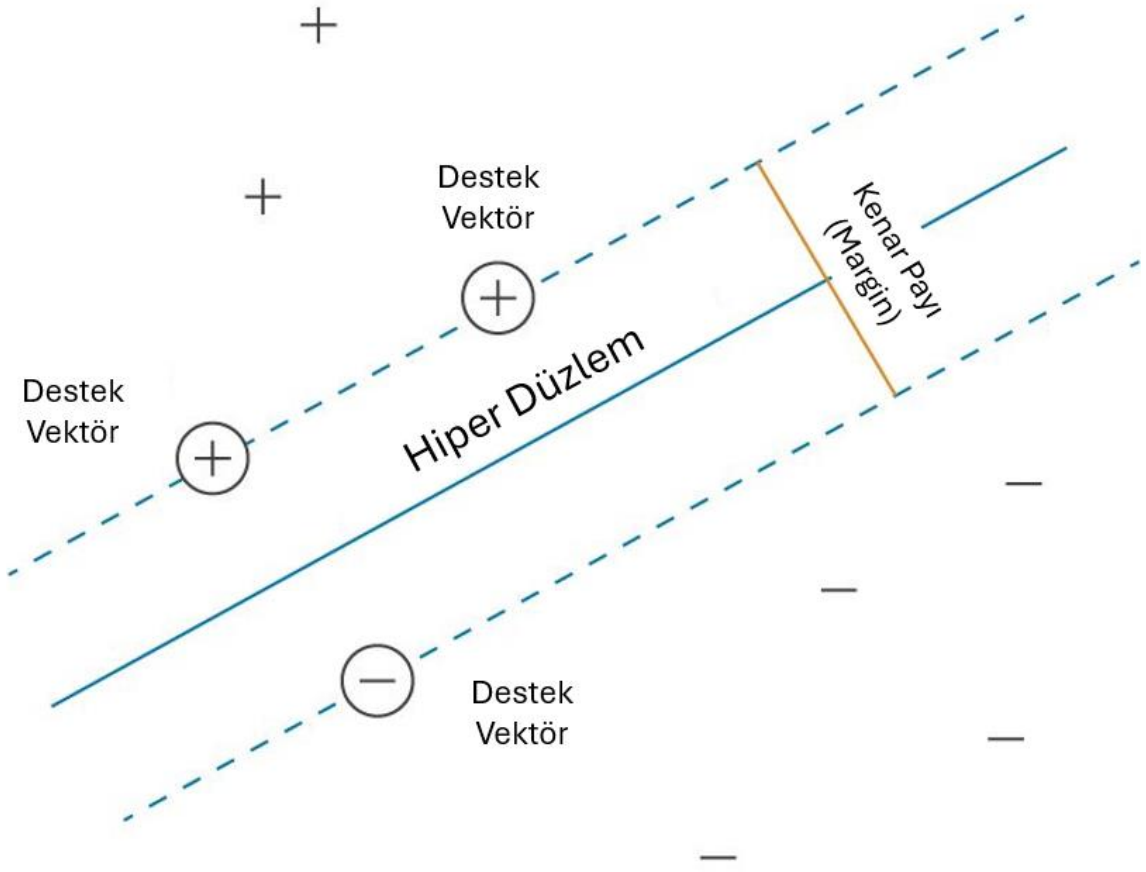

Şekil 2.9 Destek Vektör Makineleri Hiper düzlem Yerleşimi

Özetle destek vektör makineleri, verilerdeki farklı sınıfları ayırmak için en uygun hiper düzlemleri bularak sınıflandırma görevlerinde üstünlük sağlayan çok yönlü makine öğrenimi algoritmalarıdır. Doğrusal olmayan verileri, yüksek boyutlu özellik uzaylarını ve çeşitli uygulamaları ele alma yetenekleri, onları makine öğrenimi ve örüntü tanıma alanında popüler bir seçim haline getirmektedir. Bir önceki kısımda bahsettiğimiz gibi radarların tanımlanması probleminde de sağladığı güçlü yönleri ile destek vektör makineleri algoritmaları kullanılmaktadır. SVM algoritmaları ile çift polarizasyonlu radar ölçümleri kullanılarak hidrometeor sınıflandırması için araştırılmış ve geleneksel hedef tanımlamanın ötesinde radar uygulamaları için potansiyelini kanıtlamıştır [34]. SVM algoritmaları ayrıca

düşük sinyal-gürültü oranlı radar hedef tespitinde de kullanılmış ve zorlu radar ortamlarındaki kullanılabilirliğini göstermiştir [35].

2.7.2. K-En Yakın Komşu Algoritmaları

K-En Yakın Komşular (k-Nearest Neighbour) algoritması, örnek tabanlı öğrenme algoritmaları kategorisine giren klasik bir denetimli makine öğrenimi algoritmasıdır. KNN'de bir veri noktasının sınıflandırılması, özellik uzayındaki en yakın komşularının sınıfına göre belirlenir. KNN'deki "k", sınıflandırma için dikkate alınan en yakın komşu sayısını temsil eder. Yeni bir veri noktası sınıflandırılacağı zaman, algoritma bu nokta ile eğitim veri kümesindeki diğer tüm noktalar arasındaki mesafeyi hesaplar. Daha sonra bu mesafe metriğine göre en yakın "k" kadar veri noktasını seçer ve sınıf etiketini bu komşular arasındaki çoğunluk sınıfına atar. KNN algoritmasının en önemli avantajlarından biri basitliği ve uygulama kolaylığıdır. Tüm eğitim veri noktalarını ve etiketlerini sakladığı için yoğun bir eğitim aşaması gerektirmez. Ayrıca, kNN parametrik olmayan bir algoritmadır, yani giriş olarak verilen veri dağılımı hakkında herhangi bir varsayımda bulunmaz. Bu esneklik, kNN'nin karmaşık karar sınırlarına sahip olanlar da dahil olmak üzere zorlu veri kümelerinde de etkili olmasını sağlar. Ayrıca, kNN genellikle karar sınırının düzensiz olduğu veya veri dağılımının iyi tanımlanmadığı senaryolarda kullanılır. Özellikle karar sınırlarının doğrusal olmadığı sınıflandırma görevleri için kullanışlıdır [36]. Basitliği, parametrik olmayan yapısı ve doğrusal olmayan karar sınırlarını ele almadaki etkinliği ile bilinir, bu da onu çeşitli sınıflandırma görevlerinde değerli bir araç haline getirir.

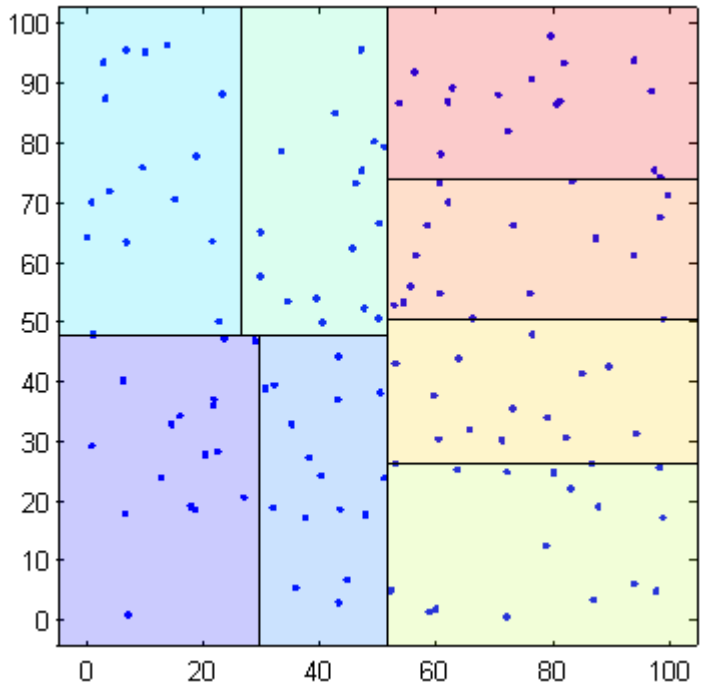

Şekil 2.10 k-En Yakın Komşular Sınıflandırma Örneği

K-En Yakın Komşular algoritması, radar tanımlama uygulamalarında, özellikle radar dedektörlerinin tasarımında ve hedef sınıflandırmasında araştırılmıştır. KNN algoritmasını kullanarak radar tanımlayıcı tasarımına yeni bir yaklaşım üzerine bir çalışma yürütülmüştür. Bu araştırma, radar sinyal işlemede yanlış alarm oranları, sabit yanlış alarm oranları ve dağınıklık gibi hususları vurgulayarak radar tanımlayıcılar için kNN kullanımına odaklanmıştır [37]. KNN algoritmasının veri noktalarını bilinen veri örneklerine yakınlıklarına göre sınıflandırma yeteneği, onu farklı radar sinyallerini veya parazitleri ayırt etmenin gerekli olduğu radar tanımlama görevleri için uygun hale getirir. Radar sistemleri, kNN algoritmasından yararlanarak radar sinyallerini özelliklerine ve karakteristiklerine göre etkili bir şekilde sınıflandırabilir ve böylece radar hedeflerinin daha iyi tanımlanmasına ve parazitlerin bastırılmasına katkıda bulunabilir. Ayrıca, kNN algoritmasının basitliği ve sınıflandırma görevlerini yerine getirmedeki etkinliği, onu radar tanımlama senaryolarında değerli bir araç haline getirmektedir. Farklı radar veri özelliklerine uyum sağlama ve radar sinyallerini bilinen örneklere yakınlığına göre verimli bir şekilde sınıflandırma yeteneği, radar sistemlerinin hedef tanıma ve sinyal işleme alanındaki genel performansını artırır.

2.7.3. Karar Ağacı Algoritmaları

Karar Ağacı (Decision Tree), sınıflandırma ve regresyon görevleri için yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. Her iç düğümün bir özelliği veya niteliği

temsil ettiği, her dalın bir karar kuralını ifade ettiği ve her yaprak düğümünün sonucu veya sınıf etiketini gösterdiği bir ağaç olarak yapılandırılmıştır. Karar Ağaçları, modelin karar verme sürecini anlamaya yardımcı olan yorumlanabilirlik ve görselleştirme yetenekleri açısından çok faydalıdır. Radar tanımlama uygulamalarında, karar ağaçları çeşitli amaçlar için kullanılmıştır. Örneğin, radar sinyallerinin sınıflandırılmasında karar ağaçları, farklı türdeki radar sinyallerini kendilerine has özelliklerine göre ayrıştırmak için etkin bir şekilde kullanılmıştır [38]. Buna ek olarak, Karar Ağaçları radar verilerinden çıkarılan belirli özellikleri kullanarak çeşitli radar hedefleri arasındaki ayrımı kolaylaştırarak radar hedef tanımlama görevlerinde etkili olmuştur [39]. Ayrıca Lin ve arkadaşlarının yaptığı araştırmada karar ağaçları, derin öğrenme tekniklerinin entegrasyonu yoluyla bilinmeyen radar sinyallerini tanımlamak için radar dalga formu tanımada uygulama alanı bulmuştur [40]. Radar sinyal özelliklerine dayalı karar ağaçları geliştirerek, bu modeller radar dalga formlarını doğru bir şekilde sınıflandırabilir ve tanıyabilir, böylece radar sinyal işleme ve analizini geliştirebilir. Karar ağaçları radar sinyallerini sınıflandırmak, radar hedefleri arasında ayrım yapmak ve radar verilerinden çıkarılan belirli özelliklere dayalı olarak çeşitli radar dalga biçimlerini tanımak için sistematik bir yaklaşım sunarak radar tanımlama görevlerinde önemli bir rol oynadığı ve hibrit algoritmalarda kullanılabilirliğinin kanıtlanmış olması ile kullanışlı bir algoritma olduğu görülmektedir.

2.7.4. Yapay Sinir Ağları Algoritmaları

Yapay Sinir Ağları (Artificial Neural Networks), insan beyninin yapısı ve işleyişinden esinlenen algoritma modelleridir. ANN algoritmaları, katmanlar halinde düzenlenmiş birbirine bağlı düğümlerden veya yapay nöronlardan oluşur. Bu katmanlar tipik olarak bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içerir. Nöronlar arasındaki her bağlantı, içinden geçen sinyali modüle eden bir ağırlıkla ilişkilendirilir. ANN algoritmaları, verilerdeki kalıpları ve ilişkileri öğrenmek için bu ağırlıkların ayarlanması yöntemi kullanılarak eğitilir. Radar tanımlama alanında ANN algoritmaları radar sinyali sınıflandırma, hedef tanıma ve parazit bastırma gibi çeşitli görevlere uygulanmıştır. ANN algoritmaları karmaşık radar verilerini etkili bir şekilde işleyebilir ve farklı radar sinyallerini ayırt etmeye yardımcı olan özellikleri çıkarabilir. ANN algoritmaları etiketli radar verileri üzerinde eğitilerek, örüntüleri tanımayı öğrenebilir ve giriş verilerine dayalı olarak doğru tahminler yapabilirler. Yapılan bir çalışma, radyolojideki uygulamalar da dahil olmak üzere bilgisayarla görme görevlerinde Yapay Sinir Ağları sınıfı olan Evrişimsel Sinir Ağlarının (CNN) çok kullanılan ve sonuç doğruluğu yüksek olan bir yöntem olduğunu göstermiştir

[41]. CNN algoritmaları, doğru sınıflandırma için radar görüntülerinden özelliklerin uzamsal hiyerarşilerini çıkarmada güçlü olduklarından, görüntü tabanlı radar tanımlama görevlerinde etkili olmuştur.

Ayrıca, ANN algoritmaları bilinmeyen radar sinyallerini tanımlamak için radar dalga formu tanımada kullanılmıştır. ANN algoritmaları çeşitli radar dalga biçimlerini tanımada ve radar sinyal tanımlama doğruluğunu artırmada potansiyel vaat etmektedir. Sonuç olarak, Yapay Sinir Ağları karmaşık radar verilerini işleyebilen, ilgili özellikleri çıkarabilen ve doğru tahminler yapabilen güçlü radar tanımlama araçlarıdır. Verilerden örüntüleri öğrenme yetenekleri, onları radar sinyal sınıflandırması, hedef tanıma ve dağınıklık bastırma gibi görevlerde değerli kılar. Şekil 2.11'de bu bölümde bahsedilen; giriş, gizli ve çıkış katmanları ile bu katmanlar arasındaki örnek bir ilişki gösterilmiştir.

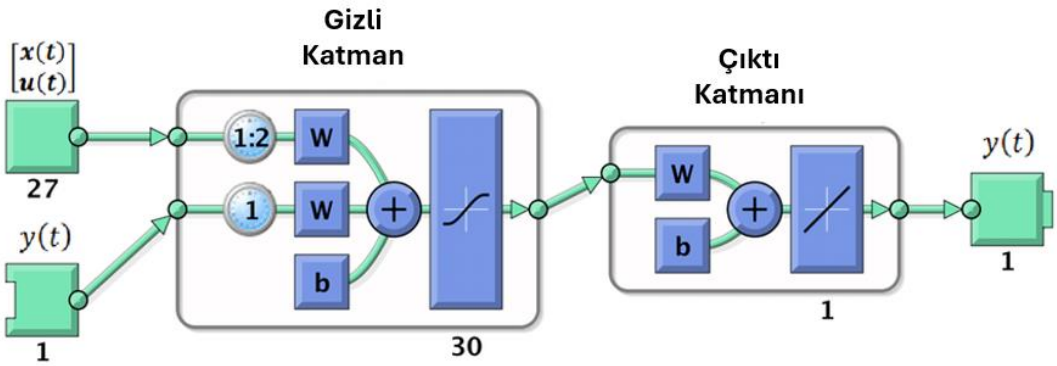

Şekil 2.11 Yapay Sinir Ağları Katmanları [42]

2.7.5. Topluluk Yöntemleri Algoritmaları

Makine öğrenmesinde topluluk yöntemleri (Ensemble Methods), daha güçlü bir tahmin modeli oluşturmak için birden fazla bireysel modeli birleştiren teknikleri ifade eder. Bu yöntemler, birden fazla modelin çeşitliliğinden yararlanarak tahmin modelinin genel performansını ve güvenilirliğini artırmayı amaçlar. Topluluk yöntemleri birkaç temel modelin tahminlerini bir araya getirerek herhangi bir modelden daha iyi sonuçlar elde edebilir.

Bagging, boosting, stacking ve random forests dahil olmak üzere çeşitli topluluk yöntemleri vardır. Bagging (Bootstrap Aggregating), aynı temel öğrenme algoritmasının birden fazla örneğinin eğitim verilerinin farklı alt kümeleri üzerinde eğitilmesini ve tahminlerinin ortalama veya oylama yoluyla birleştirilmesini içerir. Öte yandan Boosting,

modellerin sırayla eğitilmesine odaklanır; burada her bir sonraki model bir öncekinin hatalarını düzelterek genel performansın artmasını sağlar. Random forests, tahmin doğruluğunu artırmak ve aşırı uyumu azaltmak için birden fazla karar ağacının tahminlerini birleştirir. Topluluk yöntemleri, aşırı uyumu azaltma, model genellemesini artırma ve gürültülü verileri etkili bir şekilde ele alma yetenekleriyle bilinir. Sınıflandırma, regresyon ve anomali tespiti de dahil olmak üzere çeşitli makine öğrenimi görevlerinde yaygın olarak kullanılırlar. Topluluk yöntemleri görüntü tanıma, doğal dil işleme ve finansal tahmin gibi çeşitli alanlarda başarıyla uygulanmıştır.

Topluluk yöntemleri, radar sinyal işlemenin doğruluğunu ve sağlamlığını artırmak için radar tanımlama uygulamalarında giderek daha fazla kullanılmaktadır. Birden fazla modeli birleştirerek, topluluk yöntemleri radar hedef tanımlama, dağınıklık bastırma ve sinyal tanıma görevlerini etkili bir şekilde geliştirebilir. Codo ve Rico-Ramirez tarafından yapılan bir çalışma, kentsel hidrolojik uygulamalar için topluluk radar tabanlı yağış tahminlerinin kullanılmasına odaklanmıştır [43]. Topluluk yöntemleri, olasılıksal radar yağış tahminleri üretmek için kullanılmış ve radar tabanlı tahminlerin doğruluğunu artırmada topluluk yöntemlerinin etkinliğini göstermiştir. Ayrıca, bilinmeyen radar sinyallerini tanımlamak için radar dalga formu tanımada topluluk yöntemleri uygulanmıştır. Bilinmeyen radar sinyali tanımlama için derin öğrenmeye dayalı bir karar füzyon modeli geliştirilmiştir. Bu yaklaşım, farklı radar dalga biçimlerini tanımada ve radar sinyali sınıflandırma doğruluğunu iyileştirmede topluluk yöntemlerinin etkinliğini göstermiştir [39]. Genel olarak topluluk yöntemleri, çeşitli radar uygulamalarında radar sinyal işleme, hedef tanımlama, dağınıklık bastırma ve sinyal tanımayı geliştirmek için birden fazla modelin güçlü yönlerini birleştirerek radar tanımlama görevlerinde önemli rolü olduğu ispatlanmış, gelecekte kullanımı açısından potansiyeli yüksek bir algoritma yöntemi olarak görülmektedir.

3. RADAR SİNYAL KÜTÜPHANESİ

Radar sinyal kütüphaneleri, radar sistemlerinin çeşitli uygulamalar için önceden programlanması için gereklidir. Bu kütüphaneler radar sinyallerini depolar ve düzenler, verimli sinyal işleme, sınıflandırma ve izleme sağlar. Ön programlama uzmanları, hedef tanımlama, parazit algılama ve dalga biçimi analizi gibi görevler için önceden programlanmış radar sinyallerinden oluşan bir kütüphaneye erişebilirler. Radar sinyal kütüphanelerinin önemli bir yönü, radar sinyallerinin etkili bir şekilde sıralanması ve depolanmasıdır. Bu yöntem, özellikle gerçek zamanlı karar verme gerektiren senaryolarda radar verilerinin alınmasını ve işlenmesini kolaylaştırır. Ayrıca, radar sinyal kütüphaneleri parazit tahmini ve parazit bastırma gibi görevler için de değerlidir. Radar sistemleri, makine öğrenmesi algoritmaları ve kapsamlı bir tehdit sinyalleri kütüphanesi kullanarak potansiyel tehditleri etkili bir şekilde tahmin edebilir ve bunlara karşı koyabilir [44]. Radar sinyal kütüphaneleri bilişsel izleme ve manevra hedefleri için de faydalıdır. Bu yaklaşım, radar sistemlerinin kütüphanedeki önceden programlanmış dalga biçimi seçeneklerini kullanarak dinamik hedef hareketlerine uyum sağlayabilmesini sağlar [45].

Radar sinyal kütüphanesi içinde bulunan sinyallerin parametreleri darbe tanımlayıcı kelime (DTK) olarak isimlendirilir. Çalışmamız için radar sinyal kütüphanesini oluşturulurken çeşitli kaynaklardan faydalanarak farklı görevlerde ve farklı sinyal parametresi aralıklarına sahip radarları dahil edilmiştir. Çalışmanın çıktısı olan algoritmaların kullanıldığı platform özellikle hava platformları hedeflenerek kurgulanmış ve bu nedenle kütüphaneye eklenen radarlar hava platformlarına tehdit oluşturacak şekilde seçilmiştir. Radarların ana görevlerine göre jenerik frekans aralıkları Tablo 3.1'de gösterilmiştir.

Tablo 3.1 Radar görevlerine göre frekans aralıkları

Frekans Aralığı	**Ana Fonksiyon**
L bandı (1-2 GHz arası)	Erken İhbar Radarları
S bandı (2-4 GHz arası)	Erken İhbar Radarları Hava Gözetleme Radarları
C bandı (4-8 GHz arası)	Hava Savunma Radarları
X bandı (8-12 GHz arası)	Navigasyon Radarları Silah Kontrol (Güdüm) Radarları Hava Platformu Radarları

3.1. Erken Uyarı ve Hava Gözetleme Radarları

Erken uyarı radarları, zamanında müdahale eylemlerini mümkün kılmak için potansiyel tehditleri tespit etmek ve izlemek için çok önemlidir. Bu radarlar, savunma mekanizmalarının veya tahliye prosedürlerinin etkinleştirilmesine olanak tanıyacak şekilde gelen nesneleri veya olayları önceden bildirmek üzere tasarlanmıştır. Erken uyarı radarlarının en önemli özelliklerinden biri, hedefleri etkili bir şekilde tespit etmek için Doppler Etkilerinden yararlanma yetenekleridir. Bu yetenek, radarın hareketli nesneler ile sabit dağınıklığı ayırt etmesini sağlayarak hedef tanımlama ve izlemeyi geliştirir [46]. Füze savunması bağlamında, uzun menzilli erken uyarı radarları, düşman füzelerinin fırlatma aşamasında tespit edilmesi ve sınıflandırılmasında önemli bir rol oynamaktadır. Bu radarlar, füze fırlatmalarını tespit ederek ve müdahale karşı tedbirlerini hızlı bir şekilde başlatarak savunma hattı ilk katmanı olarak hizmet vermektedir. Bunlara ek olarak, radar sinyalleri için karıştırmayı tahmin etmede makine öğrenimi algoritmalarının kullanılması, radarın potansiyel tehditleri etkili bir şekilde tahmin etme ve bunlara karşı koyma yeteneğini geliştirmektedir.

Şekil 3.1 AN/TPS-63 Kısa/Orta Menzilli Radar Sistemi

Çalışmamızda kullandığımız erken uyarı radarları ve sinyal parametreleri Tablo 3.2'de verilmiştir.

Tablo 3.2 Erken Uyarı Radarları Parametreleri

Radar Adı	Frekans Aralığı	Darbe Tekrarlama Frekansı	Darbe Genişliği	Darbe Gücü	Menzil	Hüzme Genişliği
AN/TPS-63	1225-1400 MHz	300 / 375 / 500 / 750 Hz	41 µs	100 kW	370 km	2,7º
AN/TPS-59	1215-1400 MHz	180 / 625 Hz	0.18 / 1 µs	46 kW	740 km	3,2º
RRP-117	1215- 1400 MHz	250 / 1100 Hz	100 / 800 µs	20 kW	463 km	3,4°
AR-325	2700- 3100 MHz	270-1400 Hz	200 µs	135 kW	470 km	1.4°
ASR-10SS	2900 MHz	710-1032 Hz	1 / 100 µs	19,5 kW	148 km	1,4°
RAWS-03	3100- 3500 MHz	500 / 1000 / 4000 Hz	67 / 35 / 9 µs	100 kW	130 km	1.55°
1L117	2695- 3115 MHz	375 / 750 Hz	1,2 µs	700 kW	450 km	1°

3.2. Hava Savunma ve Atış Kontrol Radarları

Hava savunma ve silah yönlendirme radarları, hava tehditlerini etkili bir şekilde vurmak için hava araçlarını tespit ederek, izleyerek ve silahları yönlendirerek savunma sistemlerinde kritik bir rol oynar. Bu radarlar doğru hedef tespiti ve angajmanı sağlamak için gelişmiş teknolojiler ve stratejiler kullanır. Hava radarlarının kritik işlevlerinden biri de karıştırma girişimlerine etkin bir şekilde karşı koyabilmeleridir. Hava savunma ve silah güdüm radarları savunma sistemlerinin ayrılmaz bir parçasıdır ve karmaşık operasyonel ortamlarda gelişmiş teknolojiler aracılığıyla anti-parazit yeteneklerini, hedef izleme doğruluğunu ve silah güdüm hassasiyetini geliştirir.

Şekil 3.2 AN/MPQ-53 PATRIOT Füze Güdüm Radarı

Çalışmamızda kullandığımız hava savunma ve atış kontrol radarları ve sinyal parametreleri Tablo 3.3’te verilmiştir.

Tablo 3.3 Hava Savunma ve Atış Kontrol Radarları Parametreleri

Radar Adı	Frekans Aralığı	Darbe Tekrarlama Frekansı	Darbe Genişliği	Darbe Gücü	Menzil	Hüzme Genişliği
1RL123E	1000 – 1500 MHz	250 – 750 Hz	200 – 600 µs	-	350 km	4°
92N6E	2900 – 3300 MHz	500 – 1000 Hz	1 – 25 µs	-	-	1°
N-22	3000 – 3400 MHz	1000 Hz	10 µs	90 kW	100 km	1°
S-75	4900 – 5100 MHz	828 – 1440 / 1656- 2880 Hz	0,4- 1,2 µs	1500 kW	150 km	2°
AN/MPS-16	5200- 5300 MHz	300- 364 Hz,	2.5 µs	1000 kW	370 km	2,4°
VRRVY	5200 MHz	60 / 720 Hz	1 / 2 µs	400 kW	300 km	1,4°
S 613	5300- 5400 MHz	300 Hz	5 µs	1000 kW	-	2,7°
AN/SPS-67	5450- 5825 MHz	750 / 1200 / 2400 Hz	1 / 0.25 / 0.1 µs	280 kW	104 km	1,6°
AN/MPQ-53	5000 – 5500 MHz	500 – 1000 Hz	0,4 / 1,3 / 2,0 / 2,7 / 50 µs	10 kW	170 km	2°
S-125	9000 – 9400 MHz	1750 / 3500 Hz	0.26 / 0.5 µs	210 kW	80 km	1°
AN/SPG-34	9000 – 9500 MHz	1500 / 5000 Hz	0,25 – 0,50 µs	30 kW	23	2,4°

3.3. Hava Platformu Radarları

Hava platformu radarları, havadan gelen tehditleri etkin bir şekilde tespit etmek, izlemek ve durdurmaktan sorumlu savunma sistemlerinin temel bileşenleridir. Bu radarlar, hassas hedef tespiti ve angajmanı sağlamak için gelişmiş teknolojiler ve stratejiler içerir. Hava önleme radarlarının önemli bir özelliği, gerçek zamanlı isabet olasılığı tahminlerine dayalı olarak silah-hedef atamalarını optimize etme kabiliyetleridir. Bu radarlar, her hedef için yüksek isabet olasılığına sahip önleyiciler konuşlandırarak, önleme görevlerinin başarı oranını önemli ölçüde artırır. Ayrıca, optimum yönlendirme yasalarının ve uyarlanabilir yayılan dalga biçimlerinin koordinasyonu, önleme ve buluşma zorluklarının üstesinden

gelmek için hayati önem taşımaktadır. Bu radarlar, önleme radarlarının hedeflere göre göreceli konum ve hızlarını tahmin etmek için Kalman filtrelerini kullanarak, önleme hassasiyetini ve verimliliğini artırır. Bunlara ek olarak, MIMO radar ve karıştırıcı yöntemlerinin uygulanması, hava önleme radarlarının potansiyel karıştırma tehditlerinin bulunduğu karmaşık ortamlarda operasyonlarını optimize etmelerini sağlar [47]. Karşılıklı bilgi kriterlerine dayalı fayda fonksiyonları formüle ederek, bu radarlar radar performanslarını etkili bir şekilde artırabilirler.

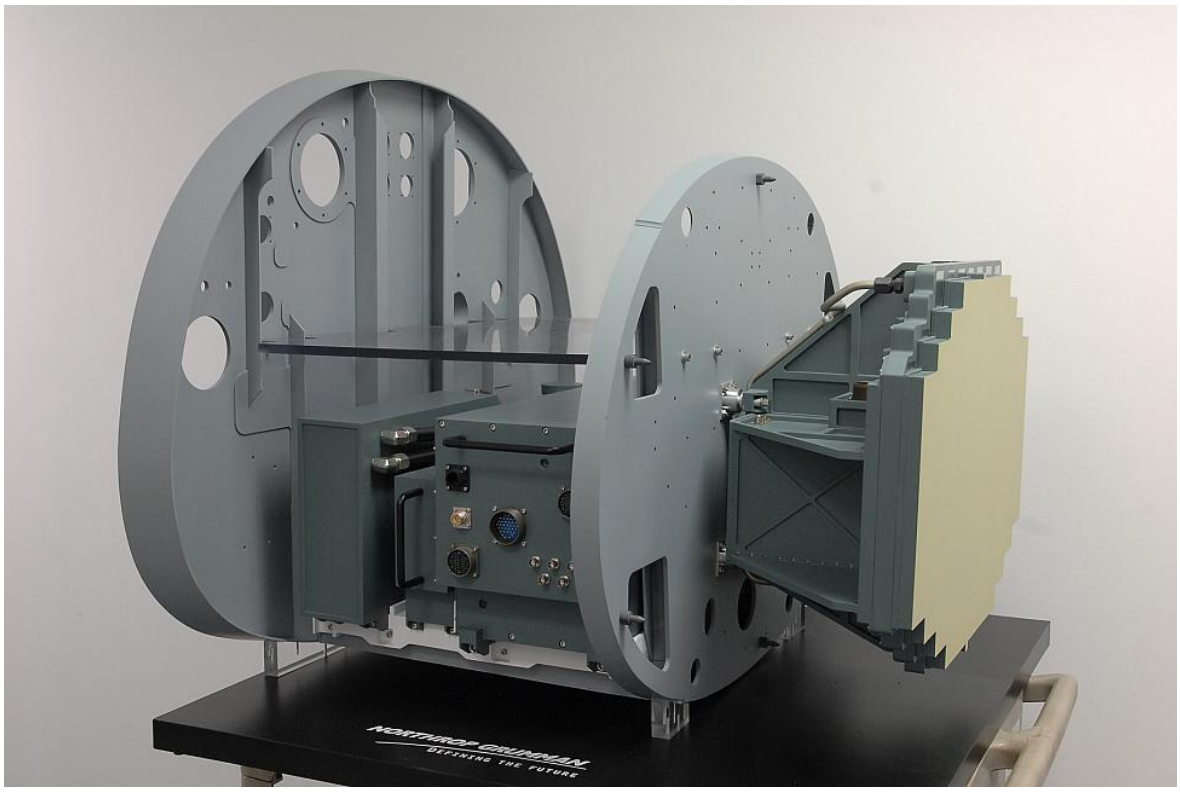

Şekil 3.3 F-16 AESA Burun Radarı

Çalışmamızda kullandığımız hava platformu radarları ve sinyal parametreleri Tablo 3.4’te verilmiştir.

Tablo 3.4 Hava Platformu Radarları Parametreleri

Radar Adı	Frekans Aralığı	Darbe Tekrarlama Frekansı	Darbe Genişliği	Darbe Gücü	Menzil	Hüzme Genişliği
SeaVue XMC	9300- 10000 MHz	388- 1854 Hz	5 / 10 / 12.3 µs	50 kW	463 km	1,3°
AN/APN-242	9375 MHz	1 024- 180 Hz	0,2- 4,5 µs	25 kW	445 km	2,4°
AN/APY-10	5000 – 5500 MHz	5000 – 1000 Hz	0,5 – 2,5 µs	-	470 km	1,5°
AN/APS-143	9250 – 9700 MHz	2491 / 1513 / 750 Hz	10 / 23,4 / 40 µs	8 kW	475 km	2°
Ocean Master	9250- 9700 MHz	300 – 125000 Hz	10 / 23,4 / 40 µs	8 kW	833 km	1°
AESA	9500 MHz	0,25- 1 Hz	0,5 – 2,5 µs	-	-	2,5°

3.4. Radar Sinyal Kütüphanesinin Oluşturulması

Tablo 3.2, Tablo 3.3 ve Tablo 3.4'te belirtilen radarların parametrelerinin bazıları aralık, bazıları birden çok sabit değer ve bazıları da tek değer olarak elde edilmiştir. Bu parametre değerleri ve aralıkları referans alınıp, radarların farklı görevleri de göz önüne alınarak, her bir radar için 60 farklı sinyal yayma senaryosu ile toplam 1440 farklı sinyal oluşturulmuştur.

Kütüphaneye eklenecek radarlar ve bu radarların parametreleri belirlendikten sonra, makine öğrenmesinde tanımlama işleminin modelini oluşturmak adına kullanılacak parametreler belirlenmiştir. Oluşturulan sinyal yayma senaryosunda darbe tanımlayıcı kelimeler için kullanılacak parametreler; frekans, darbe genişliği, darbe tekrarlama frekansı ve hüzme genişliği olarak seçilmiştir. Bu parametreler belirlenirken Tablo 2.1'de verilen, sinyal parametrelerinin tanımlama işlemine uygunluk dereceleri göz önüne alınmıştır.

4. MAKİNE ÖĞRENMESİ ALGORİTMALARININ EĞİTİLMESİ

Makine öğrenmesi algoritmalarının eğitilmesi için Matlab programının R2023a versiyonunda Classification Learner uygulaması kullanılmıştır. Bu uygulama girdi olarak verilen verileri sınıflandırmak için seçilen model parametrelerine göre modelleri eğitir. Uygulama içinde çeşitli sınıflandırma algoritmaları bulunmaktadır ve bunların konfigüre edilmesine olanak sağlamaktadır.

Model eğitildikten sonra da doğruluk karşılaştırması yapılabilmesi adına üretilen çıktılar gösterilmektedir. Bu çıktılar; geçerlenmiş modelin doğruluk oranı, dağılım grafikleri (scatter plot) ve karışıklık matrisi (confusion matrix) olarak verilmektedir. Bu özellikleri de farklı algoritmaların denenmesi, karşılaştırılması ve performans değerlendirmesi yapılabilmesi adına faydalıdır.

4.1. Model Girdilerinin Hazırlanması

Makine öğrenmesi modelleri için öncelikle veri girdilerinin tanımlanması gerekmektedir. Veri girdisi olarak tehdit kütüphanesini oluşturan 1440 farklı sinyal uygulamanın içe aktarma aracı ile tanımlanmıştır.

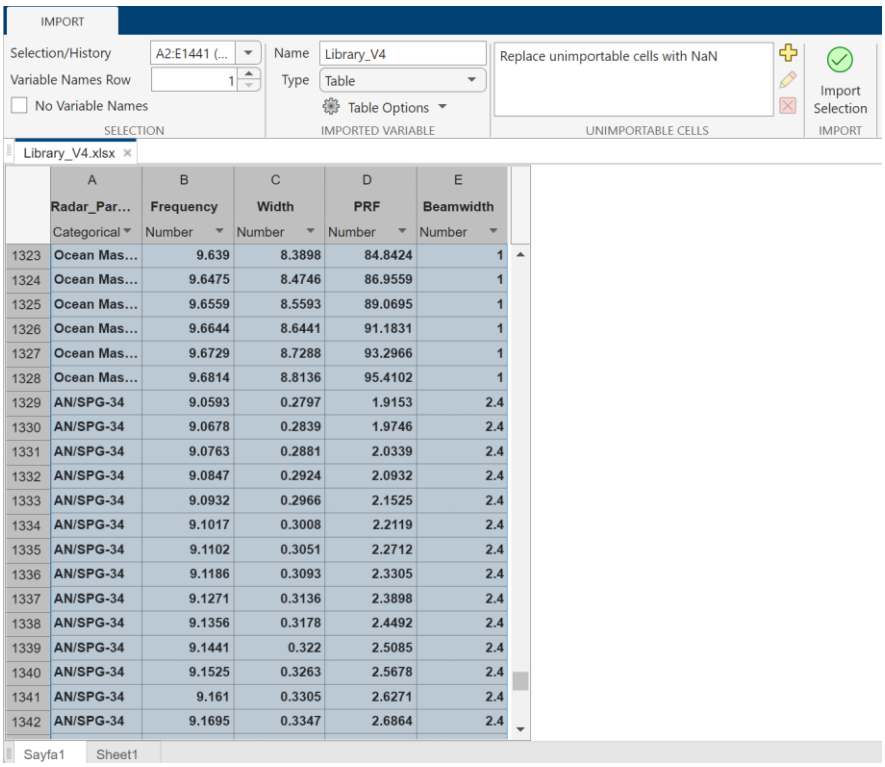

	A	B	C	D	E
	Radar_Par...	Frequency	Width	PRF	Beamwidth
	Categorical	Number	Number	Number	Number
1323	Ocean Mas...	9.639	8.3898	84.8424	1
1324	Ocean Mas...	9.6475	8.4746	86.9559	1
1325	Ocean Mas...	9.6559	8.5593	89.0695	1
1326	Ocean Mas...	9.6644	8.6441	91.1831	1
1327	Ocean Mas...	9.6729	8.7288	93.2966	1
1328	Ocean Mas...	9.6814	8.8136	95.4102	1
1329	AN/SPG-34	9.0593	0.2797	1.9153	2.4
1330	AN/SPG-34	9.0678	0.2839	1.9746	2.4
1331	AN/SPG-34	9.0763	0.2881	2.0339	2.4
1332	AN/SPG-34	9.0847	0.2924	2.0932	2.4
1333	AN/SPG-34	9.0932	0.2966	2.1525	2.4
1334	AN/SPG-34	9.1017	0.3008	2.2119	2.4
1335	AN/SPG-34	9.1102	0.3051	2.2712	2.4
1336	AN/SPG-34	9.1186	0.3093	2.3305	2.4
1337	AN/SPG-34	9.1271	0.3136	2.3898	2.4
1338	AN/SPG-34	9.1356	0.3178	2.4492	2.4
1339	AN/SPG-34	9.1441	0.322	2.5085	2.4
1340	AN/SPG-34	9.1525	0.3263	2.5678	2.4
1341	AN/SPG-34	9.161	0.3305	2.6271	2.4
1342	AN/SPG-34	9.1695	0.3347	2.6864	2.4

Şekil 4.1 Tehdit kütüphanesinin model girdisi olarak tanımlanması

Tehdit kütüphanesinin seçilmesi sonrası model geçerleme planı olarak 5 katlı çapraz geçerleme yöntemi seçilmiştir. Bu yöntemde veri seti 5 eşit parçaya bölünerek bu parçalardan 1 tanesi geçerleme yapmak için diğer 4 tanesi eğitimi gerçekleştirmek için kullanılır. Bu işlem 5 defa tekrarlanarak her parçanın diğer parçalar ile geçerleme yapılarak eğitilmesi sağlanır. Burada yapılan her iterasyon sonucu bir doğruluk performansı elde edilir. Modelin final performansı da her iterasyon için elde edilen doğruluk değerlerinin ortalamasının alınması ile elde edilir. Modelin yüksek doğruluk oranı ile eğitilmesi için katlama sayısı arttırılabilir, ancak bu da eğitim süresini arttırmaktadır. Modelde yüksek varyans ve yüksek yanlılık gibi durumlarının önüne geçebilmek adına katlama sayısının olabildiğince girdi olarak verilen kütüphanedeki veri sayısına uygun olması gerekmektedir. Matlab uygulamasında veri sayısı da göz önüne alınarak 5 katlı iterasyon seçilmiş ve modellerin girdileri hazır hale getirilmiştir.

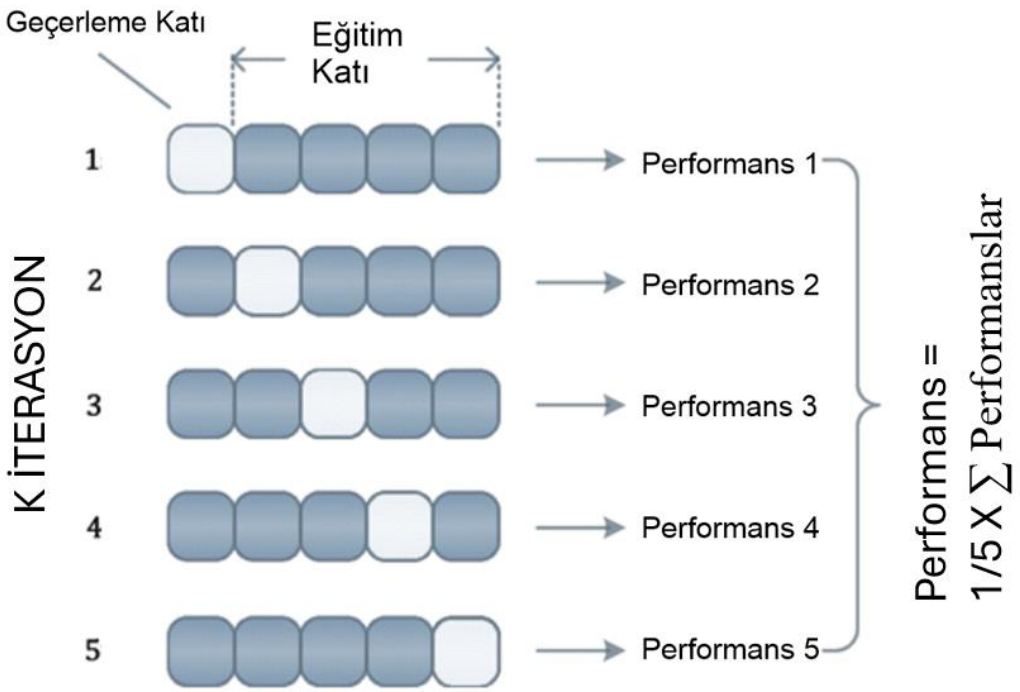

Şekil 4.2 5 Katlı Çapraz Katlama Yöntemi [48]

4.2. Model Parametrelerinin Belirlenmesi

Seçilen makine öğrenmesi metotları ile oluşturulacak modellere girdileri sağlayıp eğitilme süreci başlamadan önce, modelin öğrenme yöntemleri ile ilgili parametrelerin seçilmesi gerekmektedir. Model oluşturulurken bu parametreler öğrenme performanslarını direkt etkilemektedir. Bu model parametreleri seçilirken optimum verimi almak adına

Classification Learner'de bulunan bu parametreleri otomatik optimize etme özelliği kullanılmıştır. 30 iterasyonda en iyi model performans sonucunu alacak şekilde işlem yapan bu özellik ile modellerin geçerleme performansları yükseltilmiş ve işlem süreleri kısaltılmıştır. Şekil 4.3'da Classification Learner'da seçilen optimizasyon parametreleri gösterilmiştir.

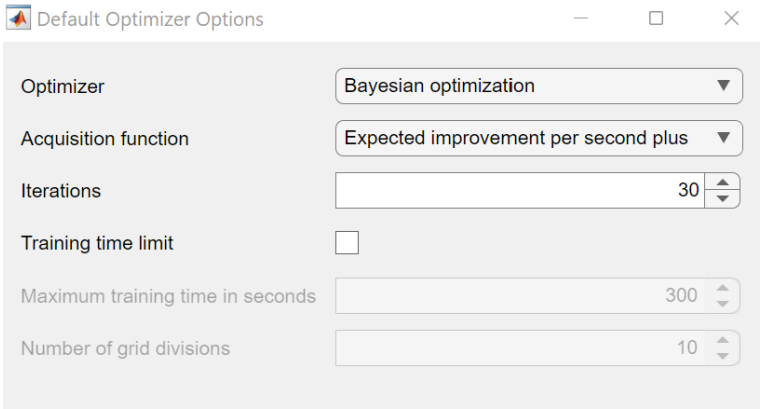

Şekil 4.3 Classification Learner optimizasyon parametreleri

4.3. Modellerin Oluşturulması

Algoritmanın eğitilmesi aşamasında ve sonuç olarak alınan parametreler performans değerlendirmesinde kullanılacağından öncelikle bunların tercih ağırlıklarının belirlenmesi gerekmektedir.

Geçerleme (öğrenme) doğruluğu; doğru olarak yapılan tahminlerin toplam yapılan gözlemlere oranıdır. Modeller oluşturulurken en kritik performans göstergesi olarak değerlendirilmektedir. Bu göstergenin yüksek olması test doğruluğunu direkt olarak etkilediğinden, oluşturulacak olan modeller simülasyonda kullanılmadan önce en yüksek oranların elde edilmesi amaçlanmıştır.

Tahmin hızı (prediction speed); öğrenme işlemi esnasında görülen performansa dayalı olarak yaklaşık olarak belirlenen yeni veri girişini gözlemleme ve tahmin oluşturma hızı olarak tanımlanmaktadır. Tahmin hızı, radar ikaz alıcısının kullanıldığı platform için hayati öneme sahip bir performans göstergesidir. Tehditlerden yayılan sinyallerin ilk tespit edildiği anda gecikmeden tanımlama yapılarak karşı tedbir alabilme yeteneği, elektronik harp konseptinde radar ikaz alıcının bulunduğu platformun üstün yeteneği olarak görülmektedir.

Eğitim süresi (training time); öğrenme işlemi sırasında geçen toplam zamandır. Bu süre diğer iki performans göstergesinin tersine önemli olarak değerlendirilmemektedir. Bunun da nedeni, modellerin oluşturulması işlemi pratik uygulamalarda ön programlama olarak bahsedilen ve zaman kısıtının önemli olmadığı bir aşamaya denk gelmektedir. Ön programlama aşaması tezin 2.3 bölümünde de açıklandığı üzere, aktif muhabere alanında gerçekleştirilmemektedir. Elektronik harp destek merkezinde bu aşama öncelikli olarak hedef yüksek geçerleme doğruluğu ve tahmin hızı olacak şekilde optimize gerçekleştirilmektedir.

Toplam hata (total cost); geçerleme doğruluğunun hesaplanmasında kullanılan yardımcı bir sonuç olarak görülmektedir ve tek başına performans göstergesi olarak değerlendirilmemektedir.

Modelin dosya boyutu (model size) da benzer şekilde bir performans göstergesi olarak değerlendirilmemektedir. Sonuç olarak öğrenme aşaması sonunda yapılacak olan performans değerlendirmesinde geçerleme (öğrenme) doğruluğu ve tahmin hızı (prediction speed) ile modeller değerlendirilmiştir.

Optimizasyon özelliğini kullanmadan yapılan model oluşturma denemelerinde alınan doğruluk oranı farklı makine öğrenmesi algoritmaları için değişiklik gösterse de %87-97 doğruluk oranı seviyelerinde gözükmektedir. Optimizasyon uygulanmadan önce alınan sonuçlara örnek olarak Şekil 4.4'de Medium KNN modelinin parametreleri ve eğitim sonrası alınan sonuçlar gösterilmektedir. Tahmin hızı yüksek olmasına rağmen geçerleme doğruluk oranının geliştirilebileceği değerlendirilmiştir.

Model 15: KNN
Status: Trained

Training Results

Accuracy (Validation)	97.4%
Total cost (Validation)	38
Prediction speed	~33000 obs/sec
Training time	1.189 sec
Model size (Compact)	~105 kB

Model Hyperparameters

Preset: Medium KNN
Number of neighbors: 10
Distance metric: Euclidean
Distance weight: Equal
Standardize data: Yes

Şekil 4.4 KNN algoritması ile oluşturulan modelin eğitim sonuçları

Geçerleme doğruluk oranını yükseltmek adına optimizasyon özelliği kullanıldığında ise doğruluk oranlarının %99'un üzerine yükseldiği gözlemlenmiştir. Doğruluk oranının yüksek olması birincil değerlendirme kriterlerinden olacağından yüksek seviyede elde edilmesi bu kriterde benzer sonuçlar gösteren algoritmalar için farklı değerlendirme kriterlerinin de kayıt altında alınması gerektiğini göstermiştir. KNN algoritması ile oluşturulan optimize edilmiş modelin parametreleri ve eğitim sonrası alınan sonuçlar Şekil 4.5'de gösterilmektedir. Tahmin hızının düştüğü gözlemlenmesine rağmen geçerleme doğruluk oranının kayıpsız tahmin seviyesine yaklaşması ile kabul edilebilir bir performans olarak görülmüştür.

Model 6: Optimizable KNN
Status: Tested

Training Results

Accuracy (Validation)	99.9%
Total cost (Validation)	2
Prediction speed	~21000 obs/sec
Training time	49.519 sec
Model size (Compact)	~105 kB

Şekil 4.5 KNN algoritması ile oluşturulan ve optimize edilen modelin eğitim sonuçları

Kullanılan diğer makine öğrenmesi algoritmaları da KNN ile aynı optimizasyon işlemi ile eğitildiğinde oluşan modellerde yüksek doğruluk oranları elde edilmiştir. Daha önce bahsedildiği gibi, öğrenme doğruluk oranı tüm algoritma modelleri için %99'un üzerinde olduğundan tahmin hızının simülasyon ortamındaki etkisi çalışmanın devamında değerlendirilmek üzere önem kazanmıştır. Yapay Sinir Ağları, Topluluk Yöntemleri, Destek Vektör Makineleri ve Karar Ağacı algoritma modelleri için alınan sonuçlar da Şekil 4.6'da gösterilmiştir.

Model 8: Optimizable Neural Network
Status: Tested

Training Results

Accuracy (Validation)	99.7%
Total cost (Validation)	4
Prediction speed	~83000 obs/sec
Training time	984.98 sec
Model size (Compact)	~83 kB

Model 7: Optimizable Ensemble
Status: Tested

Training Results

Accuracy (Validation)	99.7%
Total cost (Validation)	5
Prediction speed	~4900 obs/sec
Training time	166 sec
Model size (Compact)	~740 kB

Model 5: Optimizable SVM
Status: Tested

Training Results

Accuracy (Validation)	100.0%
Total cost (Validation)	0
Prediction speed	~3000 obs/sec
Training time	1395.8 sec
Model size (Compact)	~1 MB

Model 2: Optimizable Tree
Status: Tested

Training Results

Accuracy (Validation)	99.4%
Total cost (Validation)	8
Prediction speed	~29000 obs/sec
Training time	37.794 sec
Model size (Compact)	~35 kB

Şekil 4.6 YSA, Topluluk Yöntemi, DVM ve Karar Ağacı Öğrenme Modelleri

Algoritmaların simülasyonda kullanmak üzere modelleri oluşturulduğunda, bu modellerin çıktısı olarak değerlendirilen parametreler ve grafikler bulunmaktadır. Çapraz katlama yöntemi ile yapılan iterasyon sürecinde her iterasyon için farklı model parametreleri kullanılarak modelin hata oranı düşürülür. Bu çıktılardan modelin faydalı model parametreleri seçilebilmektedir. Ayrıca final modelde hangi radarların yanlış sınıflandırıldığını ve hata oranlarının detaylarını gösteren grafikler bulunmaktadır.

4.3.1. K-En Yakın Komşular Algoritma Modelinin Optimizasyon Sonuçları

K-En Yakın Komşular algoritmasının modeli için Classification Learner'in işlediği optimizasyon sürecinde hatanın en az gözlemlendiği iterasyon Şekil 4.7'de gösterilmiştir.

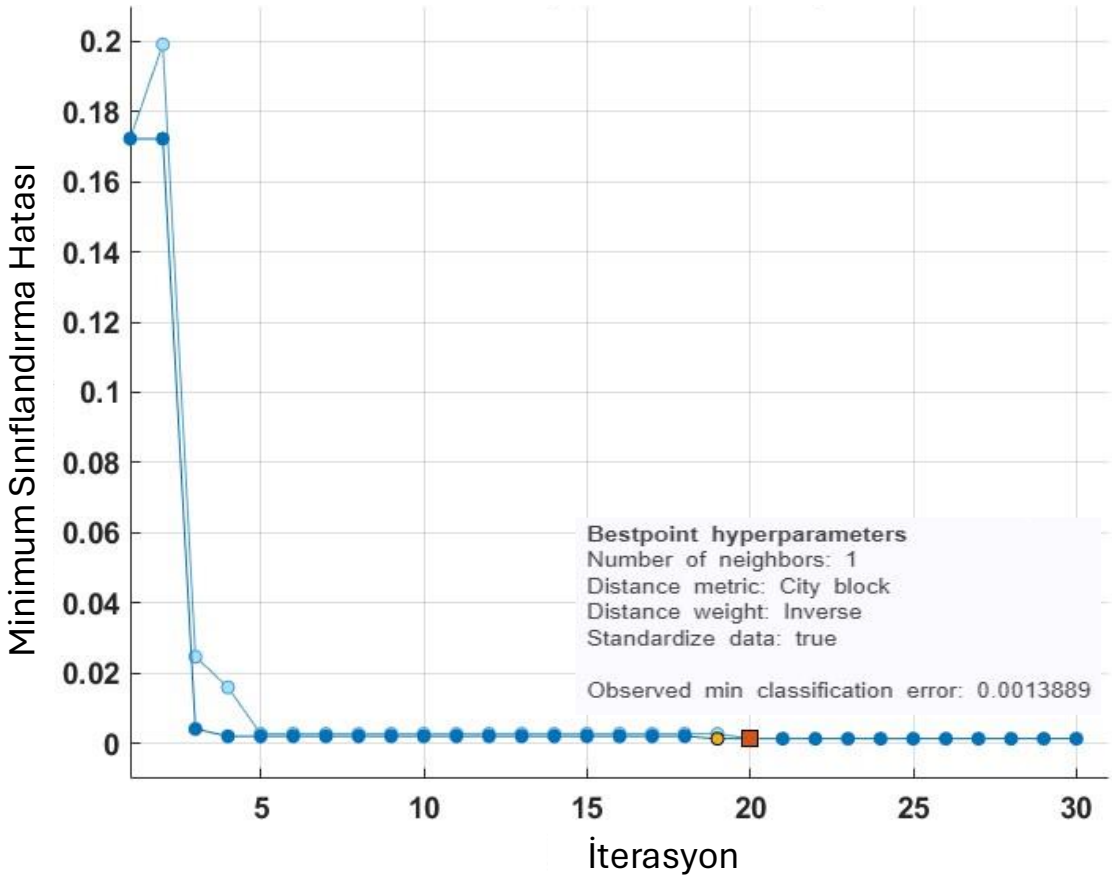

Şekil 4.7 K-En Yakın Komşular optimizasyon grafiği

Optimizasyon sonuçları ile elde edilen model parametreleri (hyperparameters); k değeri 1 olarak alınmış, uzaklık metriği olarak şehir bloğu ve ters mesafe yöntemi uygulanmıştır. Şehir bloğu metriğinde iki nokta arası mesafe bu noktaların kartezyen koordinatlarının mutlak farklarının toplamı olarak elde edilir. Bu mesafe ağırlık olarak kullanılır ve k değeri 1 olduğundan her komşu nokta ile ağırlıklar değerlendirilir. Ters mesafe yöntemi ile de komşu noktalar arasında daha yakın olan noktalar sınıflandırmada daha fazla etki sağlar.

Bu parametreler modelin oluşturulması için kullanıldığında Şekil 4.5'de gösterilen sonuçlar elde edilmiştir. Geçerleme karıştırma matrisi (validation confusion matrix) grafiğinden de yanlış yapılan gözlemler görülmektedir. Şekil 4.8'deki matriste grafiğin dikey ekseni gerçek radarı, yatay ekseni de tahmin edilen radarı ifade etmektedir. Bu matriste görüldüğü üzere; gözlemlerde yapılan tahminlerin %3,3'ü Ocean Master radarı için S-125 olarak sınıflandırılmış. Matriste buna benzer hatalar çok fazla gözlemlendiğinde, buradaki veriler modelin geliştirilmesine referans olmaktadır.

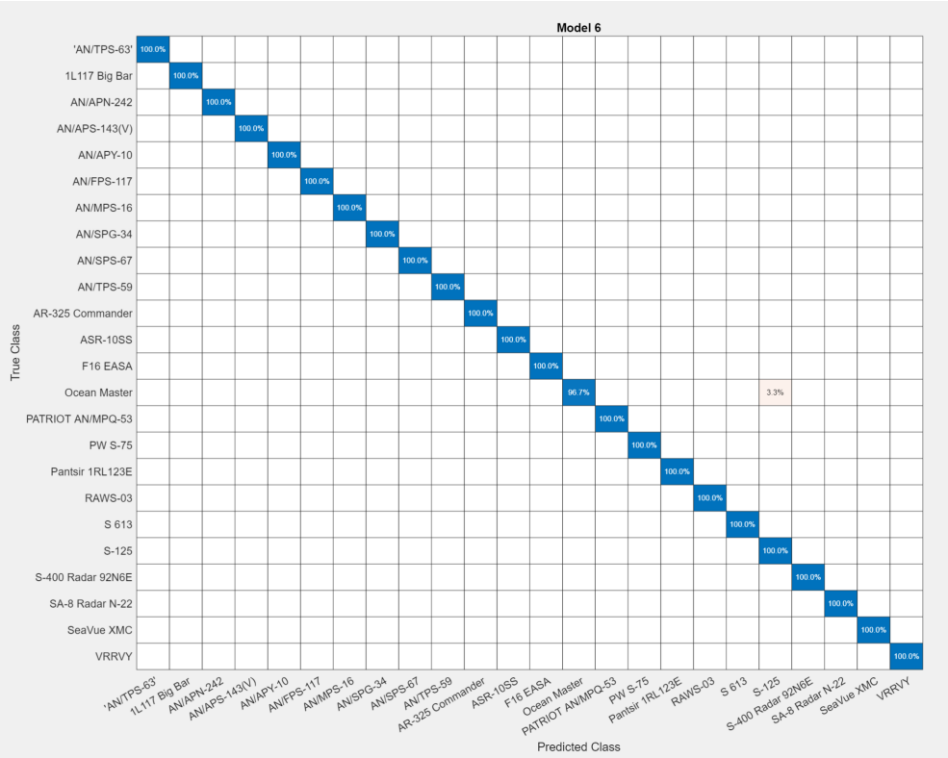

Şekil 4.8 K-En Yakın Komşular Modeli Geçerleme Karıştırma Matrisi

Grafikte görülen hatanın modelin toplam doğruluk oranına etkisi %0,01 olduğundan model simülasyonda kullanılmak üzere sonlandırılmıştır.

4.3.2. Yapay Sinir Ağları Modelinin Optimizasyon Sonuçları

Yapay Sinir Ağları algoritmasının modeli için Classification Learner'in işlediği optimizasyon sürecinde hatanın en az gözlemlendiği iterasyon Şekil 4.9'de gösterilmiştir.

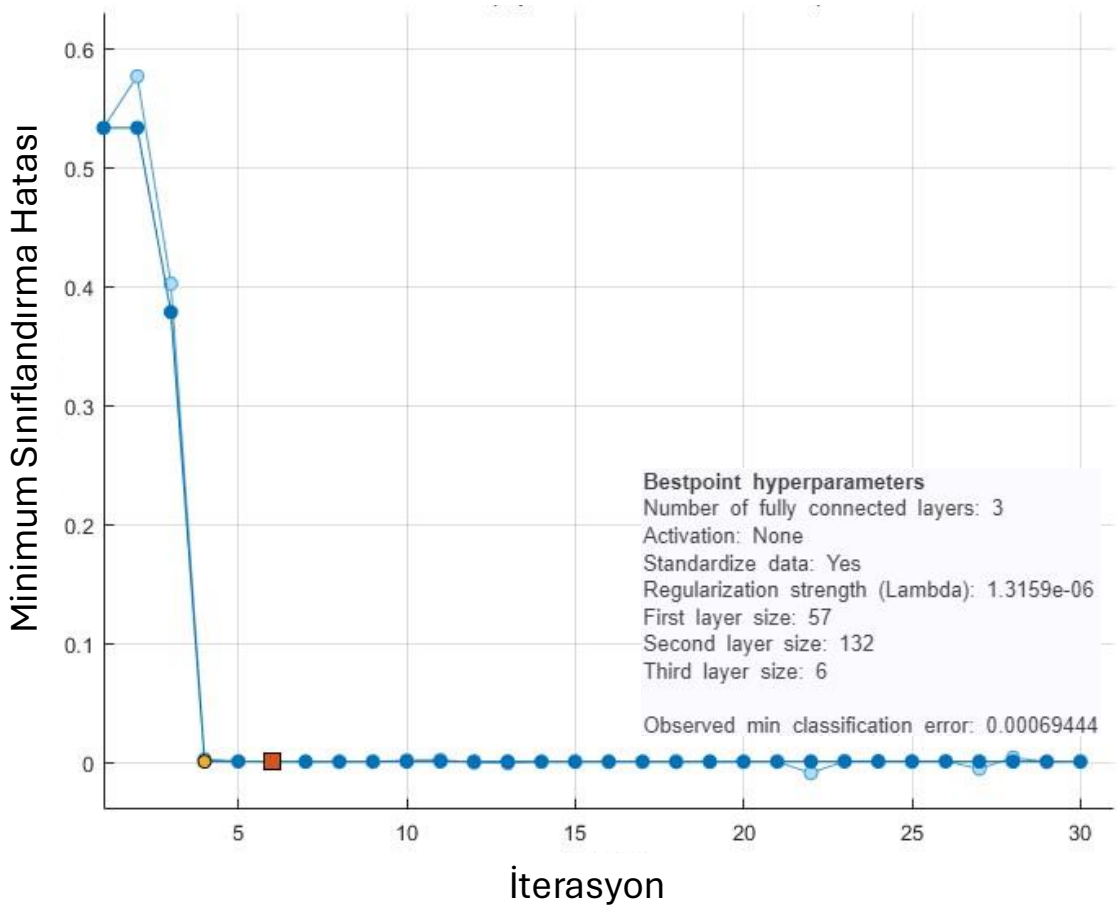

Şekil 4.9 Yapay sinir ağları optimizasyon grafiği

Yapay Sinir Ağındaki tam bağlı katmanların (fully connected layers) sayısı, ağın verilerdeki karmaşık örüntüleri ve ilişkileri öğrenme kapasitesini belirlemede çok önemli bir rol oynar. Tam bağlı katmanların derinliği ve genişliği, ağın temsil gücünü ve girdi verilerindeki karmaşık özellikleri yakalama becerisini önemli ölçüde etkiler. Yapılan testler, bir yapay sinir ağları modelinin tam bağlı katmanların sayısının artırılmasının, ağın verilerin hiyerarşik sınıflarını öğrenme kapasitesini artırarak karmaşık ilişkileri ve örüntüleri modellemesini sağlayabileceğini göstermektedir. Ancak çok fazla tam bağlı katman eklemek, ağın genelleştirilebilir kalıpları öğrenmek yerine eğitim verilerini ezberleyebileceği aşırı öğrenme riskini de büyük ölçüde arttırmaktadır. Bu nedenle, bir yapay sinir ağları modelinde tam bağlı katmanların tasarımı, model karmaşıklığı ve sınıflandırma performansı arasında bir ödünleşme içerir.

Optimize edilen modelde 3 adet tam bağlantılı katman olmasının sebebi az katmanlı yapılarda ilk katmanda tamamlanması gereken hesaplama yükünün fazla olması ile modelin öğrenme sürecini yüksek doğruluğa taşıyamama ihtimalidir. Standart uygulamalarda sınıflandırma için verilen veri parametreleri sayısında giriş katmanı düğüm sayısı tanımlansa

da giriş verilerinin birbirinden büyüklük olarak uzaklığına bağlı şekilde bu düğüm sayısı arttırılabilir. Şekil 4.9'de görülen sonuçtan optimizasyon olmadan yapılan denemelerde aldığımız görece düşük doğruluk oranlarına giriş düğüm sayısının neden olduğunu açıkça görebiliyoruz. Ayrıca 3 katmanın dahil edilmesinin ve bu 3 katman için de farklı düğüm sayılarının belirlenmesi veri setine en uygun konfigürasyonun elde edilmesini sağlayarak %99,7 geçerleme doğruluğu elde edilmesini sağlamıştır. Ayrıca düzenlileştirme gücü parametresi (regularization strength) model karmaşıklığını, sınıflandırma yeteneğini ve aşırı öğrenmeye karşı direnci etkileyen çok önemli bir parametredir. Bu parametre, eğitim sırasında düzenlileştirme teriminin genel kayıp fonksiyonu üzerindeki etkisini belirler. Yüksek bir düzenlileştirme gücü değeri, karmaşık modellere daha güçlü bir ceza uygulayarak daha basit ağırlık konfigürasyonlarını teşvik eder ve aşırı uyum riskini bu sayede azaltır [49].

Optimizasyon sonucu elde edilen parametreler modelin oluşturulması için kullanıldığında Şekil 4.6'da görülen sonuçlar elde edilmiştir. Şekil 4.10'te geçerleme karıştırma matrisi grafiğinden de yanlış yapılan gözlemler görülmektedir. Bu matriste görüldüğü üzere gözlemlerde yapılan tahminlerin; %1,7'si AN/FPS-117 radarı için AN/TPS-63 olarak, %3,3'ü AN/SPS-67 radarı için AN/APY-10 olarak ve %1,7'si Ocean Master radarı için Seavue XMC olarak sınıflandırılmış.

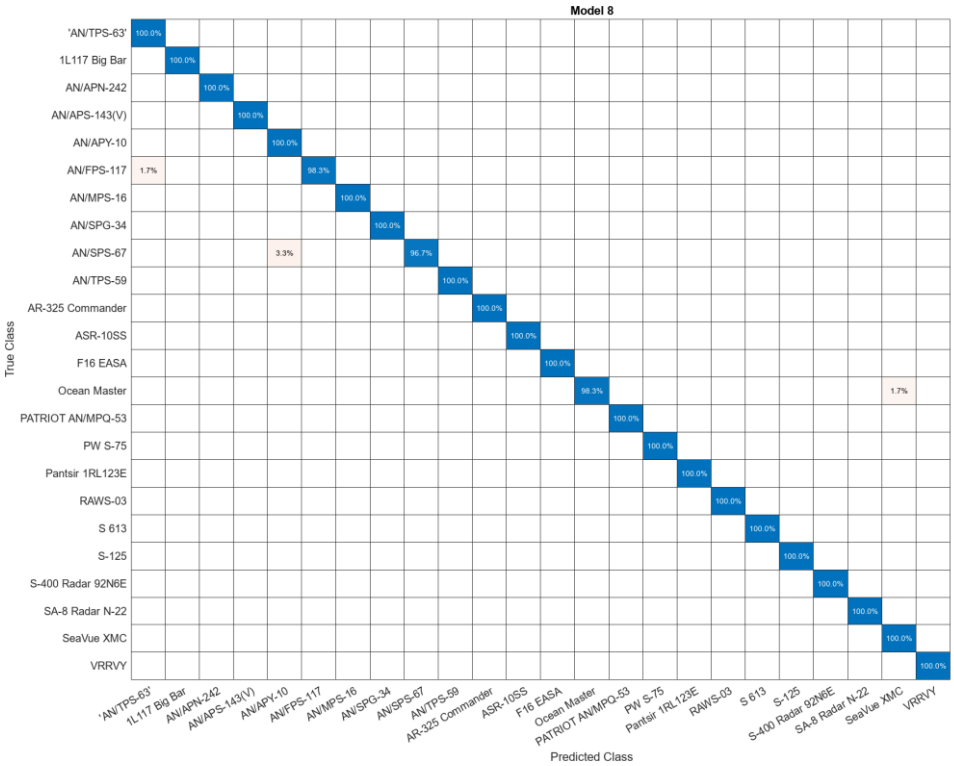

Şekil 4.10 Yapay Sinir Ağları Modeli Geçerleme Karıştırma Matrisi

Grafikte görülen hataların modelin toplam doğruluk oranına etkisi %0,03 olduğundan model simülasyonda kullanılmak üzere sonlandırılmıştır.

4.3.3. Topluluk Yöntemleri Algoritma Modelinin Optimizasyon Sonuçları

Topluluk Yöntemleri algoritmasının modeli için Classification Learner'in işlediği optimizasyon sürecinde hatanın en az gözlemlendiği iterasyon Şekil 4.11'de gösterilmiştir.

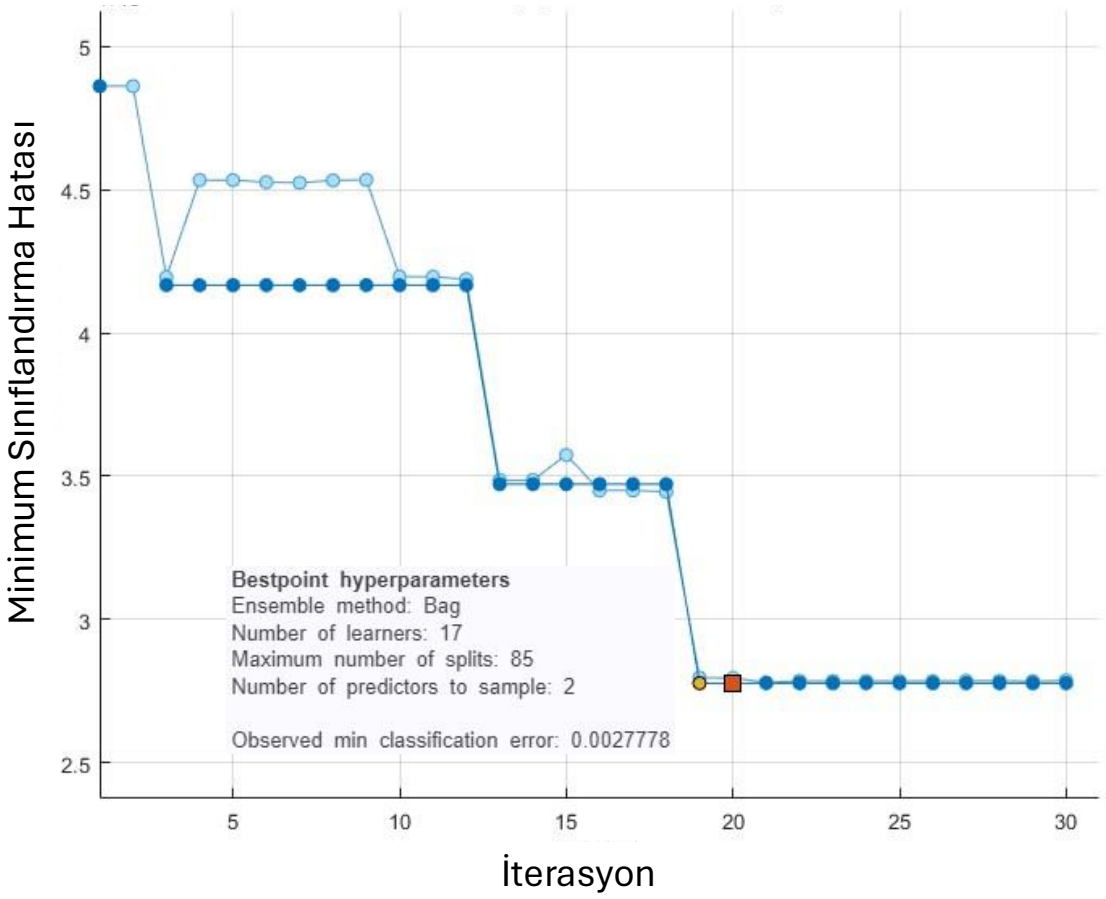

Şekil 4.11 Topluluk Yöntemleri optimizasyon grafiği

Topluluk yöntemleri için 2.7.5 bölümünde anlatılan Bagging yöntemi kullanılmıştır. Optimizasyon sonucu 17 adet karar ağacı kullanılmış, ağaçların kolları için de 85 ayrım ile sınıflandırma dalları belirlenmiştir. Araştırmalar, bir topluluktaki öğrenici sayısının artırılmasının, verilerin genellemesinin iyileştirilmesine, aşırı öğrenmenin azaltılmasına ve görünmeyen veriler üzerinde gelişmiş tahmin performansı sağladığını göstermiştir [50]. Ancak, aşırı büyük topluluklar, tahmin performansında önemli gelişmeler olmaksızın hesaplama karmaşıklığının ve eğitim süresinin artmasına neden olabilir.

Optimizasyon sonucu elde edilen parametreler modelin oluşturulması için kullanıldığında Şekil 4.6'da görülen sonuçlar elde edilmiştir. Şekil 4.12'te geçerleme karıştırma matrisi grafiğinden de yanlış yapılan gözlemler görülmektedir. Bu matriste görüldüğü üzere gözlemlerde yapılan tahminlerin; %1,7'si ASR-10SS radarı için VRRVY olarak, %3,3'ü 92N6E radarı için 1L117 olarak, %1,7'si AN/MPQ-53 radarı için PW S75 ve %1,7'si 92N6E radarı için SA-8 N22 olarak sınıflandırılmış.

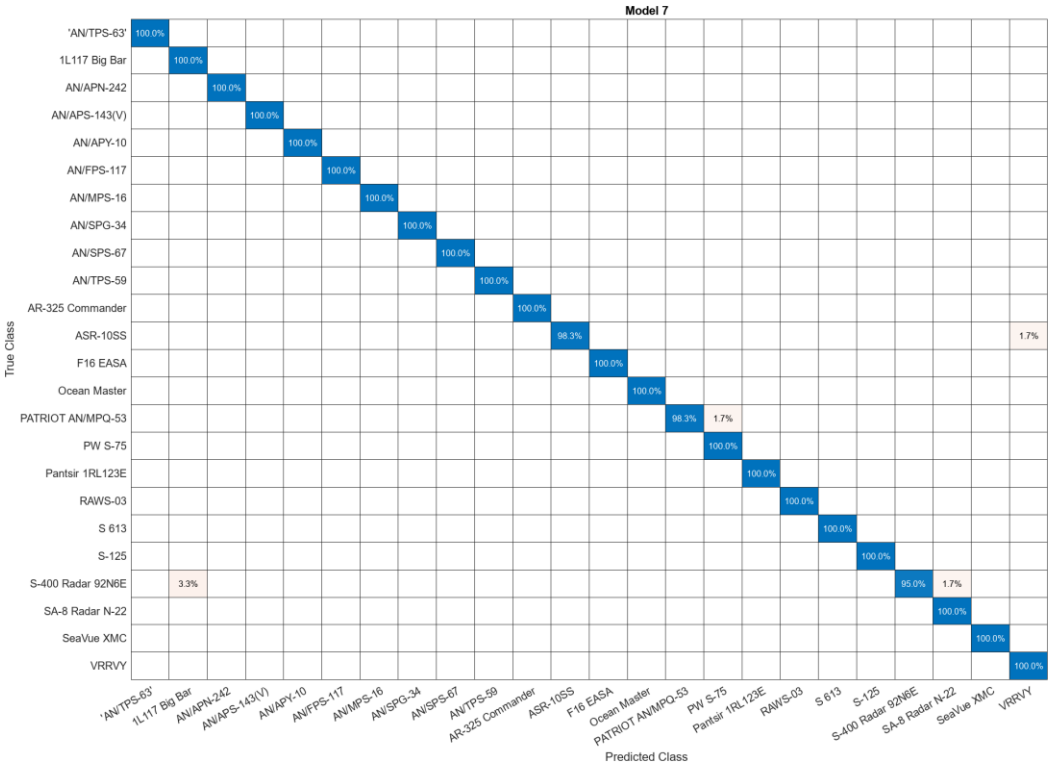

Şekil 4.12 Topluluk Yöntemleri Modeli Geçerleme Karıştırma Matrisi

Grafikte görülen hataların modelin toplam doğruluk oranına etkisi %0,03 olduğundan model simülasyonda kullanılmak üzere sonlandırılmıştır.

4.3.4. Destek Vektör Makineleri Modelinin Optimizasyon Sonuçları

Destek Vektör Makineleri algoritmasının modeli için Classification Learner'in işlediği optimizasyon sürecinde hatanın en az gözlemlendiği iterasyon Şekil 4.13'da gösterilmiştir.

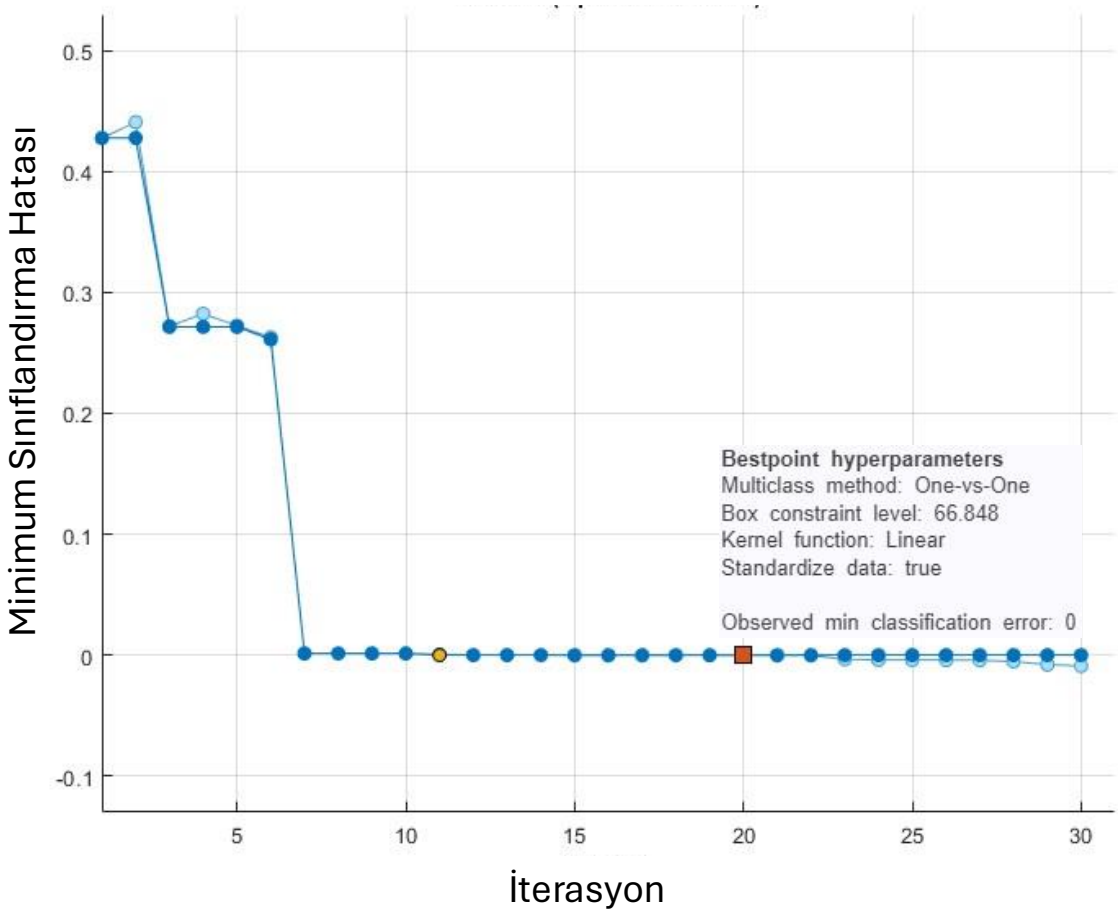

Şekil 4.13 Destek Vektör Makineleri optimizasyon grafiği

Destek vektör makinelerinin çekirdek fonksiyonu olarak lineer fonksiyon optimizasyon sonucunda en iyi sonucu verdiği görüşmüştür. One-vs-One yönteminde, veri kümesindeki her bir sınıf çifti için ayrı bir sınıflandırıcı eğitilir. Her bir sınıflandırıcının karar fonksiyonu daha sonra tahmin için yeni veriler sunulduğunda sınıf etiketini belirlemek için kullanılır. Bu yöntem, birden fazla ikili sınıflandırıcı kullanarak ve bunların çıktılarını birleştirerek, çok sınıflı sınıflandırmanın karmaşık görevini bir dizi ikili sınıflandırma alt problemine dönüştürür. Bu şekilde sınıflandırıcı her sınıfı birbirinden ayırt etmeyi öğrenir. Kutu kısıtlama seviyesi (box constraint level), marj genişliği ile sınıflandırma hatası arasındaki dengeyi yöneten bir parametredir. Bu değerin düşük olması genellikle algoritmanın lineer marjının büyümesine ve dolayısıyla bu marjın içinde daha fazla nokta bulunmasına izin vermektedir. Çok yüksek bir seviyede seçildiğinde ise veri setine göre marj içinde hiçbir veri alınmamaktadır. Kutu kısıtlama seviyesinin ayarlanması, modelinin önyargı ve varyans arasında bir denge kurması için ayar yapılmasına olanak tanır ve böylece görünmeyen veriler üzerindeki performansını artırır. Bu parametre bir bakıma modelin aşırı öğrenme ve yetersiz öğrenme durumunu engelleyecektir. Veri setine göre yapılan

optimizasyonda bu kısıtlama seviyesi 66,848 olarak belirlenmiş ve bu sayede destek vektör makineleri modelinde hiçbir hata gözlemlenmemiştir.

Optimizasyon sonucu elde edilen parametreler modelin oluşturulması için kullanıldığında Şekil 4.6'da gösterilen sonuçlar elde edilmiştir. Şekil 4.14'te geçerleme karıştırma matrisi grafiğinden de geçerleme doğruluğunun bütün radarlar için tam olarak gerçekleştirildiği görülmektedir.

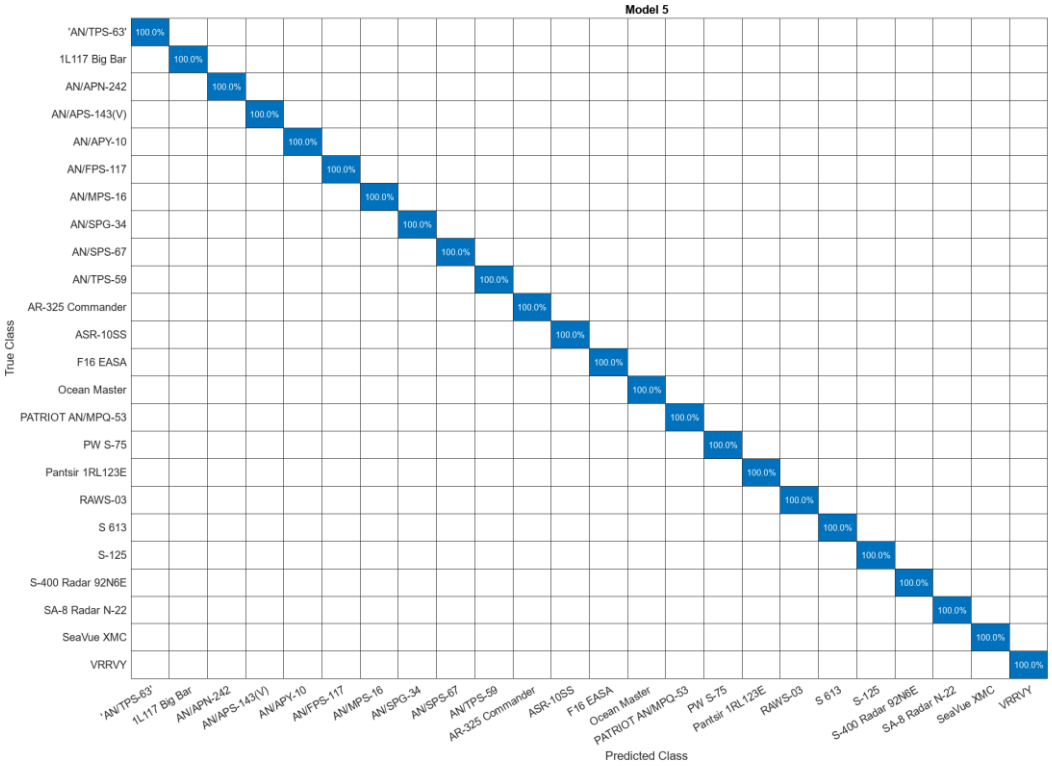

Şekil 4.14 Destek Vektör Makineleri Modeli Geçerleme Karıştırma Matrisi

4.3.5. Karar Ağacı Modelinin Optimizasyon Sonuçları

Karar ağacı algoritmasının modeli için Classification Learner'in işlediği optimizasyon sürecinde hatanın en az gözlemlendiği iterasyon Şekil 4.15'de gösterilmiştir.

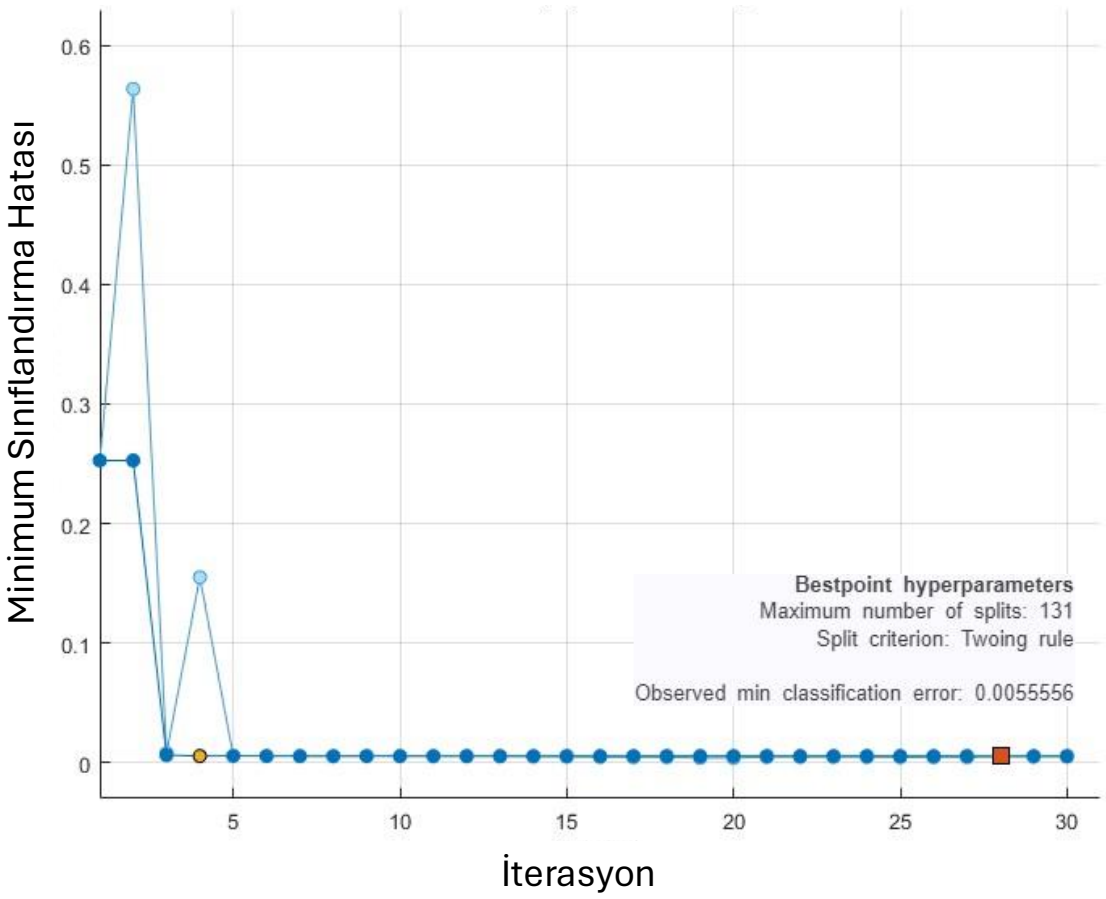

Şekil 4.15 Karar Ağacı optimizasyon grafiği

Optimizasyon işlemi sonucunda seçilen ikiye bölme kuralı (Twoing Rule); karar ağacında bulunan düğümlerin nasıl bölüneceğini belirleyen bir kuraldır. Öz ve yorumlanabilir bir model oluşturmak için karar ağacı kurallarının birleştirilmesini içerir. Ayrıca etkili karar verme için açık ve anlaşılır karar kuralları sağlar. Bu kurala göre de bölünen alt düğümlerin her birine benzer sayıda veri dağılımı yapılması ve düğümlere dağıtılın verilerin olabildiğince birbirinden farklı olması amaçlanır.

Bir karar ağacı modelindeki bölünme sayısı (number of splits), ağacın yapısını, karmaşıklığını ve tahmin performansını doğrudan etkileyen temel bir özelliktir. Bir karar ağacındaki her bölme, bir özelliğe ve bir eşik değerine dayalı bir karar noktasını temsil eder ve verilerin farklı alt kümelere bölünmesini sağlar. Bölme sayısı, ağacın derinliğini ve ağaç tarafından oluşturulan karar sınırlarının ayrıntı düzeyini belirler. Bölünme sayısını optimize etmek, model karmaşıklığı ve tahmin doğruluğu arasında bir denge sağlamak için çok önemlidir. Çok az bölünmeye sahip bir ağaç, verilerdeki altta yatan örüntüleri aşırı basitleştirerek yetersiz öğrenmeye ve tahmin gücünün azalmasına neden olabilir. Öte yandan, çok fazla bölünmeye sahip bir ağaç verilerdeki gürültüyü yakalayabilir, bu da aşırı

öğrenmeye ve görülmeyen verilere zayıf genellemeye neden olur. Yüksek eğitim doğruluğuna ulaşabilmek adına 131 dala ayrılması optimizasyon algoritması ile sağlanmış olup, karar ağacı algoritma testleri arasında en başarılı model parametresi seti belirlenmiştir.

Optimizasyon sonucu elde edilen parametreler modelin oluşturulması için kullanıldığında Şekil 4.6'da gösterilen sonuçlar elde edilmiştir. Şekil 4.16'da geçerleme karıştırma matrisi grafiğinden de yanlış yapılan gözlemler görülmektedir. Bu matriste görüldüğü üzere gözlemlerde yapılan tahminlerin; %1,7'si AR-325 radarı için RAWS-03 olarak, %1,7'ü Ocean Master radarı için SeaVue XMC olarak, %1,7'si AN/MPQ-53 radarı için PW S75, %1,7'si RAWS-03 radarı için ASR-10SS, %1,7'si PW S75 radarı için AN/MPQ-53, %3,3 92N6E radarı için 1L117 ve %1,7 92N6E radarı için SA-8 N-22 olarak sınıflandırılmıştır.

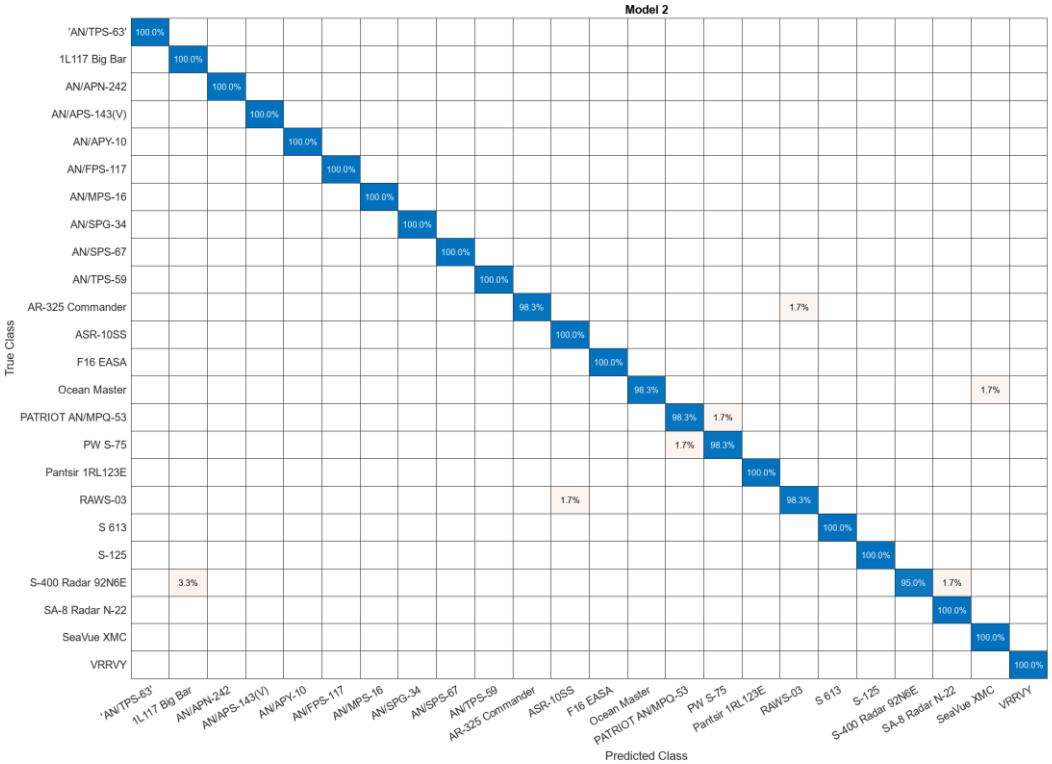

Şekil 4.16 Karar Ağacı Modeli Geçerleme Karıştırma Matrisi

Grafikte görülen hataların modelin toplam doğruluk oranına etkisi %0,06 olduğundan model simülasyonda kullanılmak üzere sonlandırılmıştır.

4.4. Final Modellerin Test Edilmesi

Bu bölümde modeller Classification Learner içinde bulunan test özelliği ile test edilmiştir. Yapılan testler validasyon esnasında gerçekleştirilen tahminlere dayalı olup tam

bir simülasyon ortamında alınması hedeflenen çıktıları sağlamasa da final modellerin doğrulanması için gereklidir.

Classification Learner'da test için girdi olması istenen verilerin seçimi mümkün olmamaktadır. Bu nedenle tehdit kütüphanesinde bulunan tüm veriler ile testler gerçekleştirilmiştir.

4.4.1. K-En Yakın Komşular Algoritma Modelinin Test Sonuçları

Oluşturulan modelin testinde, Şekil 4.17'da görüldüğü üzere tüm radarlar doğru tahmin edilmiş ve model kullanıma hazır olarak değerlendirilmiştir. K-En Yakın Komşular algoritmasının modeli "Simülasyon Senaryosu 1" olarak hem radar tanımlanmasında hem de tanımlanan radarın görevinin tahmin edilmesinde kullanılacaktır.

Modelin validasyon doğruluğunda görülen hatalar Ocean Master radarı için simülasyonda tekrar gözden geçirilecektir.

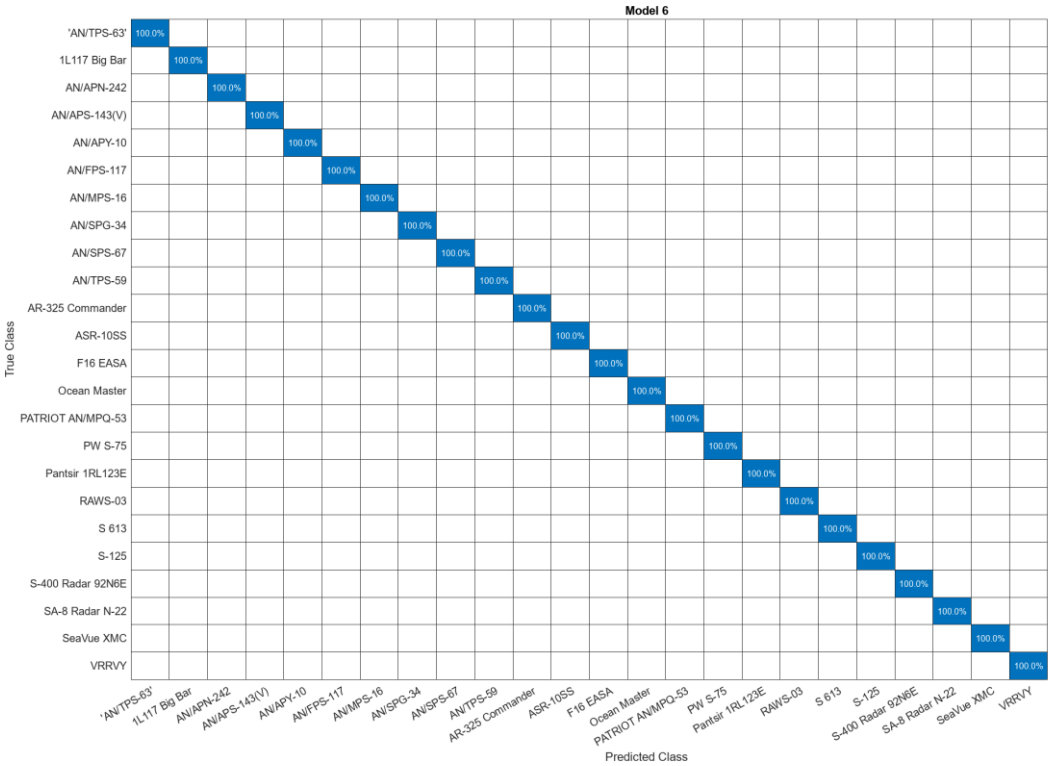

Şekil 4.17 K-En Yakın Komşular Algoritma Modelinin Test Karıştırma Matrisi

4.4.2. Yapay Sinir Ağları Algoritma Modelinin Test Sonuçları

Oluşturulan modelin testinde, Şekil 4.18'de görüldüğü üzere tüm radarlar doğru tahmin edilmiş ve model kullanıma hazır olarak değerlendirilmiştir. Yapay Sinir Ağları

algoritmasının modeli “Simülasyon Senaryosu 2” olarak hem radar tanımlanmasında hem de tanımlanan radarın görevinin tahmin edilmesinde kullanılacaktır.

Modelin validasyon doğruluğunda görülen hatalar AN/FPS-117, AN/SPS-67 ve Ocean Master radarları için simülasyonda tekrar gözden geçirilecektir.

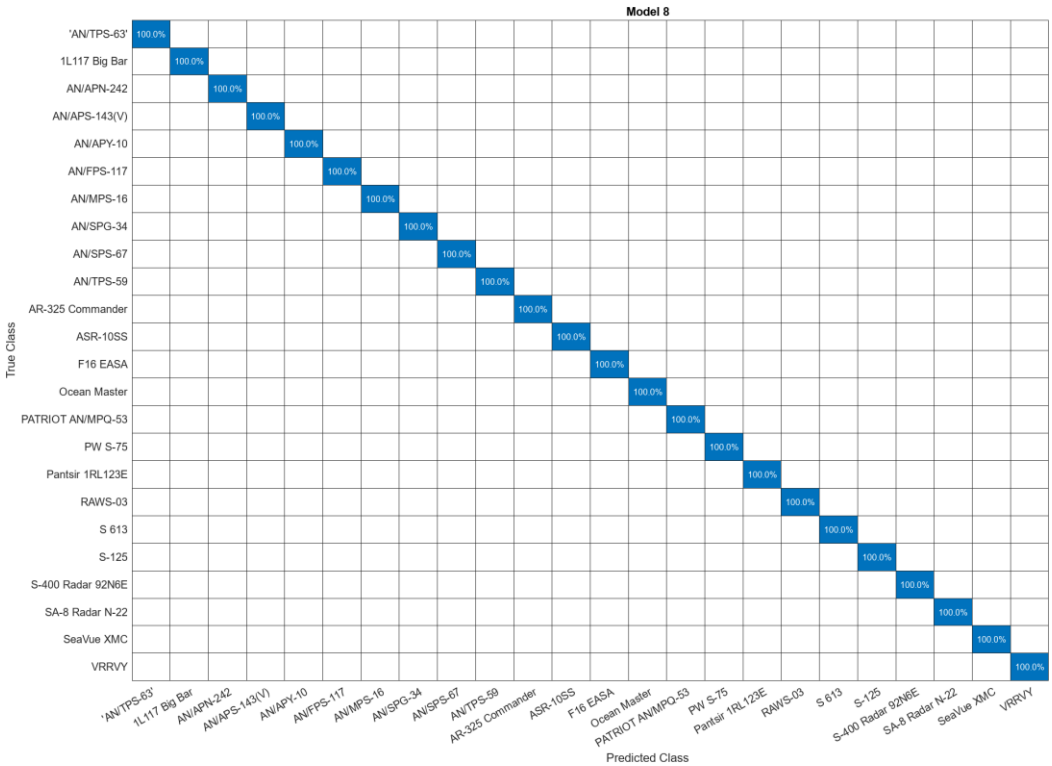

Şekil 4.18 Yapay Sinir Ağları Algoritma Modelinin Test Karıştırma Matrisi

4.4.3. Topluluk Yöntemleri Algoritma Modelinin Test Sonuçları

Oluşturulan modelin testinde, Şekil 4.19’de görüldüğü üzere tek radardaki tahminlerin %1,7’si 92N6E radarı için SA-8 N-22 radarı olarak tahmin edilmiştir. Modelin toplam hatasındaki etkisi %0,01 olduğundan model kullanıma hazır olarak değerlendirilmiştir. Topluluk Yöntemleri algoritmasının modeli “Simülasyon Senaryosu 3” olarak hem radar tanımlanmasında hem de tanımlanan radarın görevinin tahmin edilmesinde kullanılacaktır.

Modelin validasyon doğruluğunda görülen hatalar ASR-10SS, AN/MPQ-53 ve 92N6E radarları için simülasyonda tekrar gözden geçirilecektir.

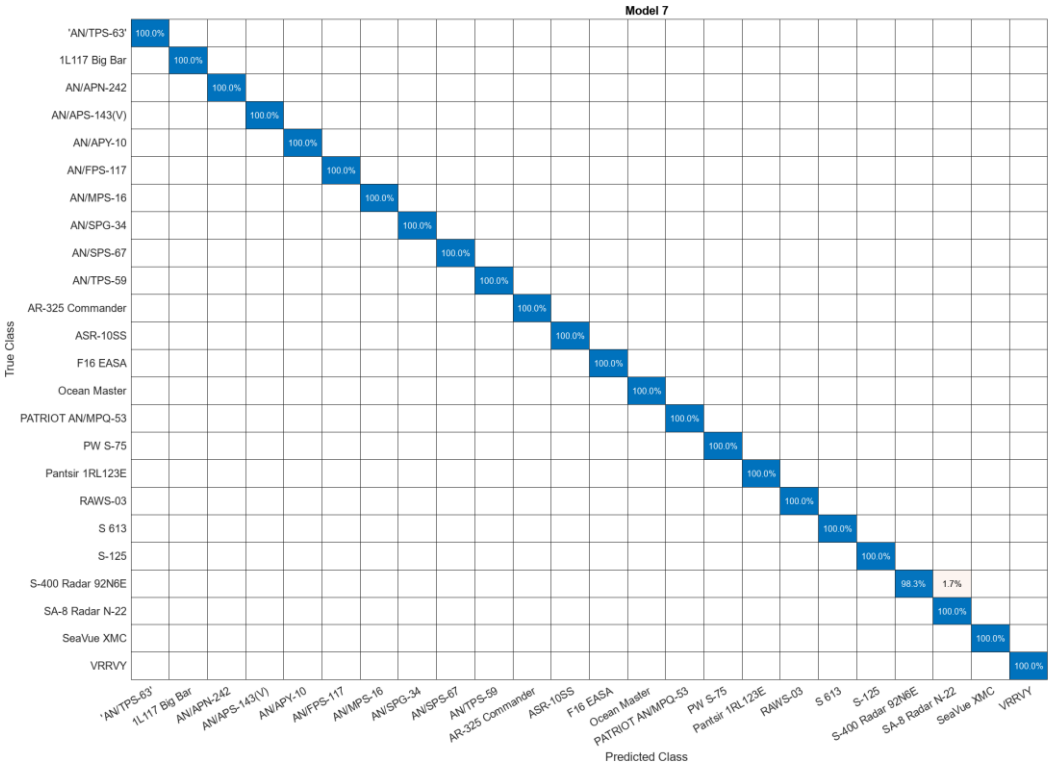

Şekil 4.19 Topluluk Yöntemleri Algoritma Modelinin Test Karıştırma Matrisi

4.4.4. Destek Vektör Makineleri Algoritma Modelinin Test Sonuçları

Oluşturulan modelin testinde, Şekil 4.20Şekil *4.19*'de görüldüğü üzere tüm radarlar doğru tahmin edilmiş ve model kullanıma hazır olarak değerlendirilmiştir. Destek Vektör Makineleri algoritmasının modeli "Simülasyon Senaryosu 4" olarak hem radar tanımlanmasında hem de tanımlanan radarın görevinin tahmin edilmesinde kullanılacaktır.

Modelin validasyon doğruluğunda hata görülmediğinden, simülasyon sonucunda görülen hatalar validasyon sonuçlarına bağlanmadan değerlendirilecektir.

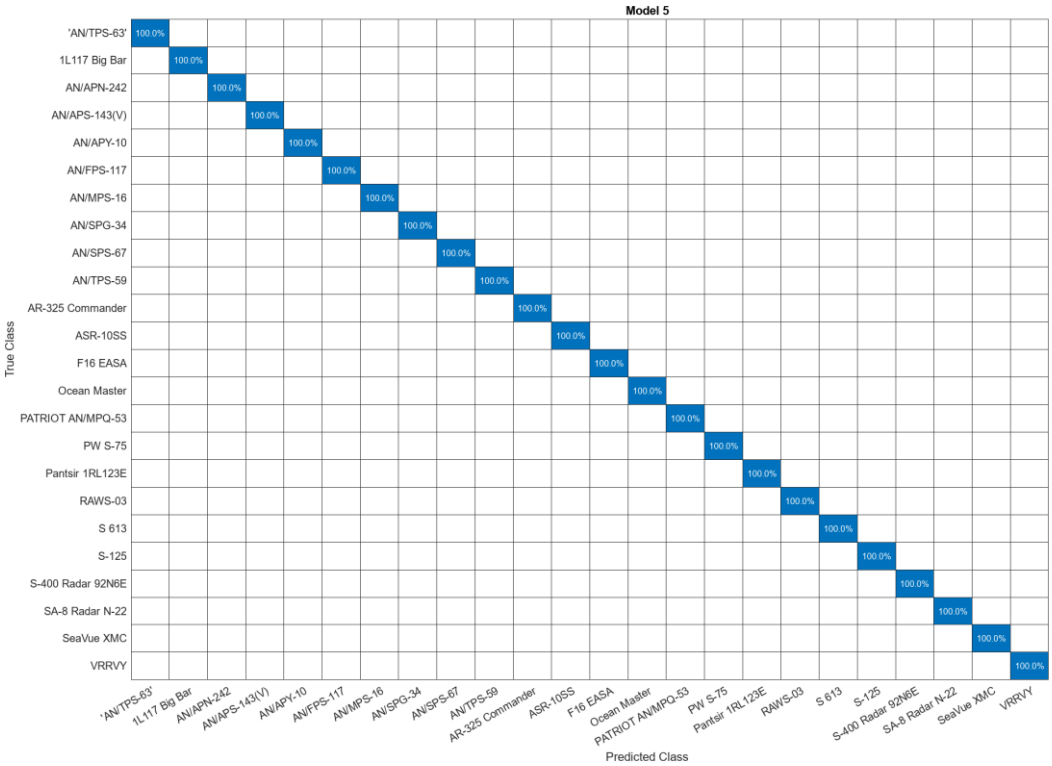

Şekil 4.20 Destek Vektör Makineleri Algoritma Modelinin Test Karıştırma Matrisi

4.4.5. Karar Ağacı Algoritma Modelinin Test Sonuçları

Oluşturulan modelin testinde, Şekil *4.19*'de görüldüğü üzere tüm radarlar doğru tahmin edilmiş ve model kullanıma hazır olarak değerlendirilmiştir. Karar Ağacı algoritmasının modeli "Simülasyon Senaryosu 5" olarak hem radar tanımlanmasında hem de tanımlanan radarın görevinin tahmin edilmesinde kullanılacaktır.

Modelin validasyon doğruluğunda görülen hatalar AR-325, Ocean Master, AN/MPQ-53, RAWS-03, PW S75 ve 92N6E radarları için simülasyonda tekrar gözden geçirilecektir.

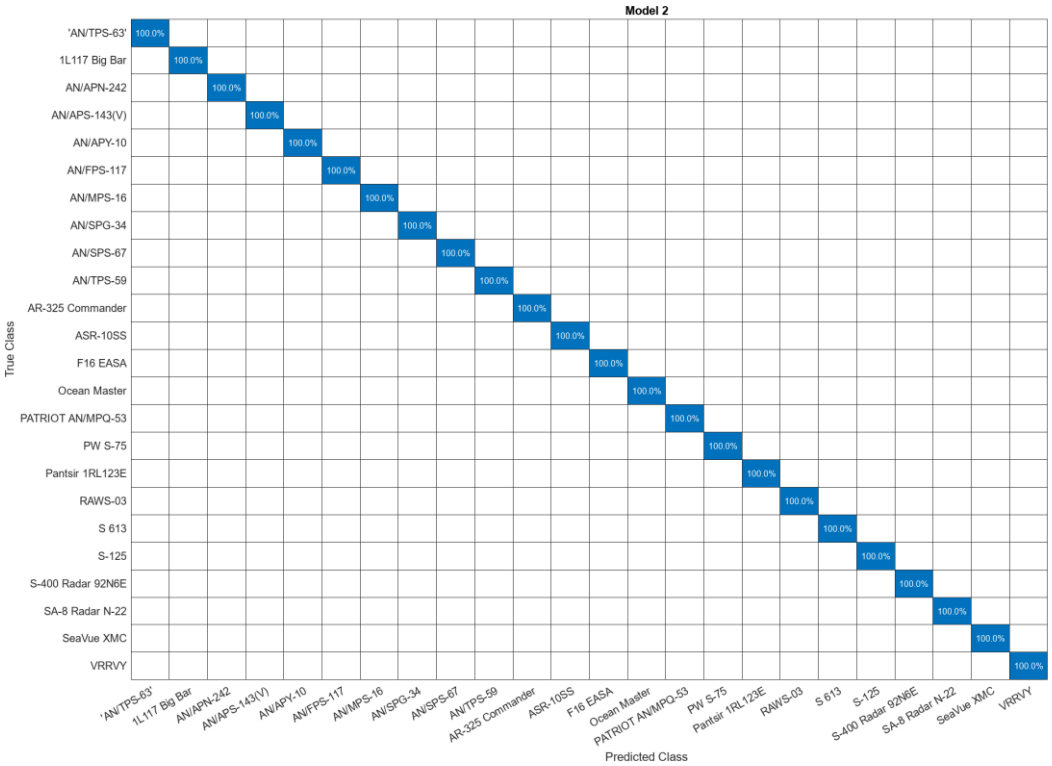

Şekil 4.21 Karar Ağacı Algoritma Modelinin Test Karıştırma Matrisi

5. MAKİNE ÖĞRENMESİ MODELLERİNİN UYGULANMASI

Önceki bölümlerde açıklanan algoritma modelleri, bu bölümde bir simülasyon algoritması ile belirleyeceğimiz görevlerde kullanılacaktır. Simülasyon algoritması Matlab'de hazırlanmış ve Classification Learner'dan dışa aktarılan modelleri kullanabilecek şekilde yapılandırılmıştır.

5.1. Simülasyon Algoritması

Oluşturulacak olan simülasyon algoritmasında, önceki bölümlerde bahsedilen birden çok radar sinyalinin bulunduğu ve zorlayıcı olarak görülen bir ortam elde edilmesi amaçlanmıştır. Bunun için ortamda çeşitli sayılarda sinyal bulunacak şekilde senaryolar planlanmıştır.

Bu algoritma ile öncelikli hedef ortamda bulunan radarların tanımlanması olmakla birlikte, tanımlanan radarların belirli varsayımlar çerçevesinde hangi görevi icra ettiği de tahmin edilecektir. Tüm bu görevler sırasında kullanılan makine öğrenmesi algoritmalarının işlemleri ne kadar sürede tamamladığı da kaydedilerek performans göstergesi olarak değerlendirilecektir.

Senaryo belirlendikten sonra simülasyon algoritmasına öncelikle tehdit kütüphanesi tanımlanacaktır. Tanımlanan kütüphaneden uygulanan senaryoya göre sayıdaki sinyal rastgele belirlenerek muharebe ortamı olarak tanımlanacaktır. Ortamdaki sinyallerin parametreleri tanımlanıp bir tablo haline getirilerek işlenmeye hazır hale getirilecektir. Senaryoya göre seçilmiş olan makine öğrenmesi algoritması tanımlama işlemini gerçekleştirip, bir tahmin edilen radarlar tablosu oluşturacaktır. Alınan sinyallerin PRF'leri için senaryoda tanımlanan değere göre radarların anlık görevleri takip veya arama olarak belirlenecektir. Sonuçlar alındıktan sonra karşılaştırma tablosu, doğru tahmin edilen radar sayısı ve işlem süresi çıktıları gösterilecektir. Simülasyon algoritmasının bu işlemleri Şekil 5.1'te fonksiyon blokları ile gösterilmiştir.

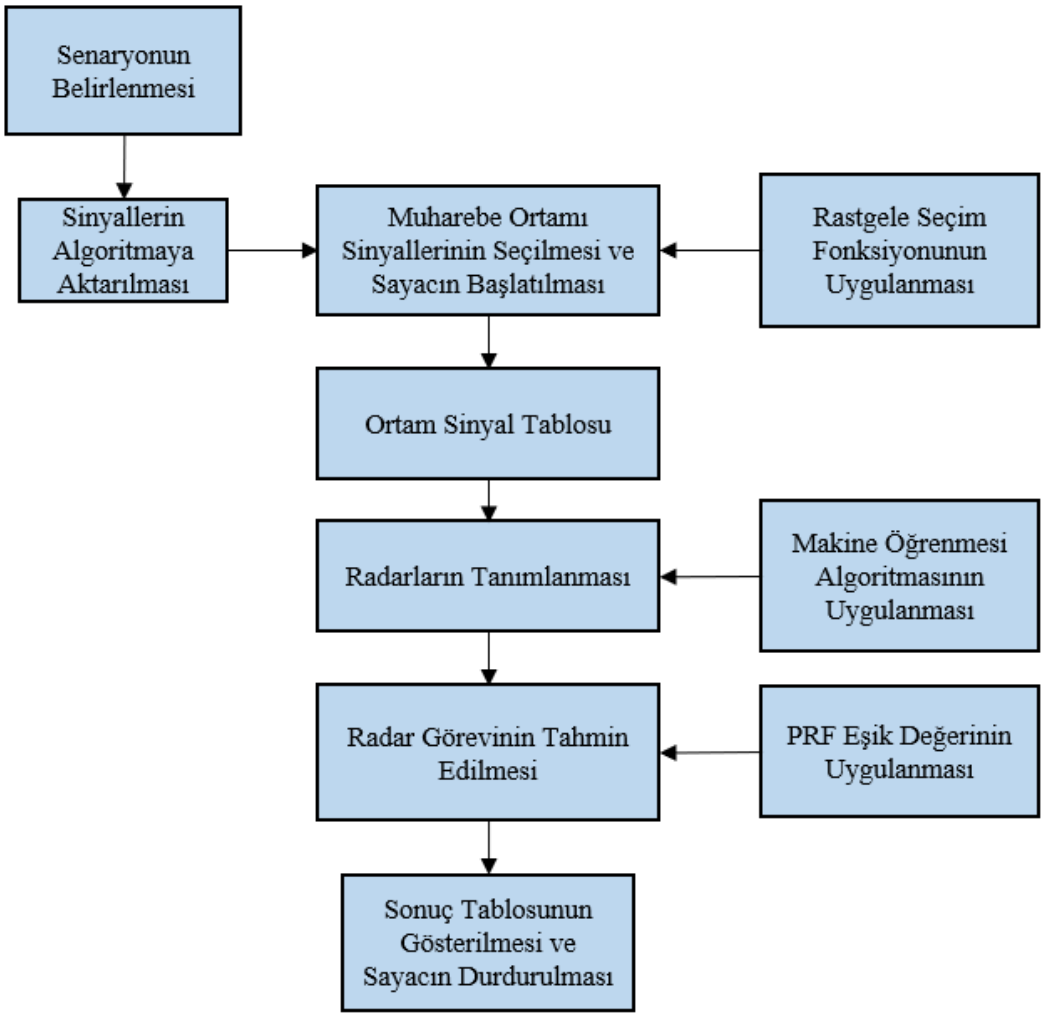

Şekil 5.1 Simülasyon Algoritması Adımları

5.2. Simülasyon Senaryoları

İki farklı değişkenin kombinasyonları ile oluşturulan senaryolar kurgulanmıştır. Bu değişkenlerden ilki muharebe ortamında aynı anda bulunacak olan radar sinyali sayısıdır. Karmaşıklığın ve işlemci yükünün artışının gözlemlenmesi beklenmektedir. İşlemci yükü artışı simülasyonda işlem süresinin artışı olarak gözlenebilecektir.

Diğer değişken ise radar sinyal parametrelerinin uygulanma şekli ile ilgilidir. İlk üç senaryoda sinyal parametreleri ile oluşturulan tehdit kütüphanesi yeterince olgunlaşmamış halde, sonraki üç senaryoda parametre aralıkları da tanımlanmış ve genişletilmiş bir tehdit kütüphanesi kullanılacaktır. Bu iki tehdit kütüphanesi sonuçları ile de darbe tanımlayıcı kelimelerin detaylı olarak belirlenmesinin radar tanımlama işleminde ne kadar etkisi olduğu görülebilecektir.

5.2.1. Senaryo 1

Bu senaryoda muharebe ortamında 20 radar sinyali bulunacaktır. Bu sinyallerin parametreleri, her parametre için sadece sınır koşulları ve matematiksel ortalamalar alınarak algoritmalara tanımlanacaktır. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır.

AN/TPS-63 radarı için alınan sinyal parametreleri örnek olarak Tablo 5.1'da gösterilmiştir. Her parametrenin sınır koşulu diğer parametrelerin sınır koşulları ile eşlenip özgün birer darbe tekrarlayıcı kelime oluşturacak şekilde tehdit veri giriş matrisi hazırlanmıştır.

Tablo 5.1 Senaryo 1-2-3 Örnek Radar Parametreleri

Radar Adı	**Frekans**	**Darbe Genişliği**	**Darbe Tekrarlama Frekansı**	**Hüzme Genişliği**
AN/TPS-63	1,23	41,00	0,38	2,700
AN/TPS-63	1,23	41,00	0,38	2,700
AN/TPS-63	1,40	41,00	0,38	2,700
AN/TPS-63	1,40	41,00	0,38	2,700
AN/TPS-63	1,23	41,00	0,30	2,700
AN/TPS-63	1,23	41,00	0,30	2,700
AN/TPS-63	1,40	41,00	0,30	2,700
AN/TPS-63	1,40	41,00	0,30	2,700
AN/TPS-63	1,23	41,00	0,50	2,700
AN/TPS-63	1,23	41,00	0,50	2,700
AN/TPS-63	1,40	41,00	0,50	2,700
AN/TPS-63	1,40	41,00	0,50	2,700
AN/TPS-63	1,23	41,00	0,75	2,700
AN/TPS-63	1,23	41,00	0,75	2,700
AN/TPS-63	1,40	41,00	0,75	2,700
AN/TPS-63	1,40	41,00	0,75	2,700

5.2.2. Senaryo 2

Bu senaryoda muharebe ortamında 50 radar sinyali bulunacaktır. Bu sinyallerin parametreleri, her parametre için sadece sınır koşulları ve matematiksel ortalamalar alınarak algoritmalara tanımlanacaktır. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır.

5.2.3. Senaryo 3

Bu senaryoda muharebe ortamında 1000 radar sinyali bulunacaktır. Bu sinyallerin parametreleri, her parametre için sadece sınır koşulları ve matematiksel ortalamalar alınarak algoritmalara tanımlanacaktır. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır.

5.2.4. Senaryo 4

Bu senaryoda muharebe ortamında 20 radar sinyali bulunacaktır. Bu sinyaller 3.4 bölümünde açıklandığı gibi oluşturulmuştur. Parametrelerin belirli sınır koşullarının yanında radarların çalışabildiği parametre aralıkları da dahil edilmiştir. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır. AN/TPS-63 radarı için alınan sinyal parametrelerinin ilk yarısı örnek olarak Tablo 5.2'da gösterilmiştir.

Tablo 5.2 Senaryo 4-5-6 Örnek Radar Parametreleri

Radar Adı	Frekans	Darbe Genişliği	Darbe Tekrarlama Frekansı	Hüzme Genişliği
'AN/TPS-63'	1,23	41,00	0,38	2,700
'AN/TPS-63'	1,23	41,00	0,39	2,700
'AN/TPS-63'	1,24	41,00	0,39	2,700
'AN/TPS-63'	1,24	41,00	0,40	2,700
'AN/TPS-63'	1,24	41,00	0,41	2,700
'AN/TPS-63'	1,24	41,00	0,41	2,700
'AN/TPS-63'	1,25	41,00	0,42	2,700
'AN/TPS-63'	1,25	41,00	0,42	2,700
'AN/TPS-63'	1,25	41,00	0,43	2,700
'AN/TPS-63'	1,26	41,00	0,44	2,700
'AN/TPS-63'	1,26	41,00	0,44	2,700
'AN/TPS-63'	1,26	41,00	0,45	2,700
'AN/TPS-63'	1,26	41,00	0,46	2,700
'AN/TPS-63'	1,27	41,00	0,46	2,700
'AN/TPS-63'	1,27	41,00	0,47	2,700
'AN/TPS-63'	1,27	41,00	0,47	2,700
'AN/TPS-63'	1,28	41,00	0,48	2,700
'AN/TPS-63'	1,28	41,00	0,49	2,700
'AN/TPS-63'	1,28	41,00	0,49	2,700
'AN/TPS-63'	1,28	41,00	0,50	2,700
'AN/TPS-63'	1,29	41,00	0,51	2,700
'AN/TPS-63'	1,29	41,00	0,51	2,700
'AN/TPS-63'	1,29	41,00	0,52	2,700
'AN/TPS-63'	1,30	41,00	0,52	2,700

5.2.5. Senaryo 5

Bu senaryoda muharebe ortamında 50 radar sinyali bulunacaktır. Bu sinyaller 3.4 bölümünde açıklandığı gibi oluşturulmuştur. Parametrelerin belirli sınır koşullarının yanında radarların çalışabildiği parametre aralıkları da dahil edilmiştir. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır.

5.2.6. Senaryo 6

Bu senaryoda muharebe ortamında 1000 radar sinyali bulunacaktır. Bu sinyaller 3.4 bölümünde açıklandığı gibi oluşturulmuştur. Parametrelerin belirli sınır koşullarının yanında radarların çalışabildiği parametre aralıkları da dahil edilmiştir. Bu senaryo hazırlanmış olan her makine öğrenmesi algoritması için tekrarlanacaktır.

5.3. Simülasyon Senaryolarının Uygulanması

Oluşturulan makine öğrenmesi algoritma modellerinin öğrenme performansları 4.3 bölümünde gösterilmişti. Öğrenme işlemi sonrası oluşturulan bu modeller, Classification Learner'in dışa aktarma fonksiyonu ile Matlab Workspace'e aktarılmış ve Şekil *5.2*'da gösterildiği bir değişken fonksiyonu olarak tanımlanmıştır. Simülasyonda kullanılacak olan makine öğrenmesi algoritması değiştirilmek istendiğinde bu işlem Classfication Learner'dan kullanılacak olan algoritma için tekrarlanmaktadır.

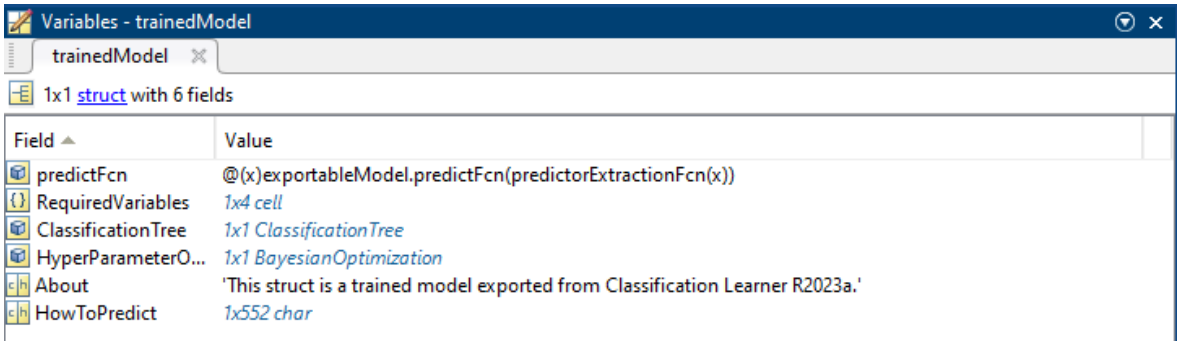

Şekil 5.2 Makine Öğrenmesi Modelinin Simülasyon Ortamına Aktarılması

6. SİMÜLASYONDA SENARYOLARIN UYGULANMASI

Simülasyon çıktısı olarak Matlab Workspace'de Şekil 6.1'de örnek olarak gösterildiği gibi bir çıktı alınmaktadır. Bu çıktılar her senaryo için tablo halinde gösterilecektir. Her senaryo içinde de tüm makine öğrenmesi algoritmaları 10 kez çalıştırılarak ortalama performansları tablolara yansıtılacaktır.

```
Command Window
>> Main14
    Number          Predicted                    Actual                Mission

      1      {'PW S-75'          }    {'PW S-75'          }    {'Scanning'}
      2      {'SA-8 Radar N-22'  }    {'S-400 Radar 92N6E'}    {'Scanning'}
      3      {'AN/APY-10'        }    {'AN/APY-10'        }    {'Scanning'}
      4      {'S-125'            }    {'S-125'            }    {'Scanning'}
      5      {'Pantsir 1RL123E'  }    {'Pantsir 1RL123E'  }    {'Scanning'}
      6      {'VRRVY'            }    {'VRRVY'            }    {'Scanning'}
      7      {'PW S-75'          }    {'PW S-75'          }    {'Scanning'}
      8      {'PATRIOT AN/MPQ-53'}    {'PATRIOT AN/MPQ-53'}    {'Scanning'}
      9      {'SeaVue XMC'       }    {'SeaVue XMC'       }    {'Scanning'}
     10      {'AN/APY-10'        }    {'AN/APY-10'        }    {'Scanning'}
     11      {'RAWS-03'          }    {'RAWS-03'          }    {'Scanning'}
     12      {'SeaVue XMC'       }    {'PATRIOT AN/MPQ-53'}    {'Scanning'}
     13      {'PW S-75'          }    {'PATRIOT AN/MPQ-53'}    {'Scanning'}
     14      {'Pantsir 1RL123E'  }    {'Pantsir 1RL123E'  }    {'Scanning'}
     15      {'AN/FPS-117'       }    {'AN/FPS-117'       }    {'Scanning'}
     16      {'S 613'            }    {'S 613'            }    {'Scanning'}
     17      {'AN/SPG-34'        }    {'AN/SPG-34'        }    {'Tracking'}
     18      {'1L117 Big Bar'    }    {'1L117 Big Bar'    }    {'Scanning'}
     19      {'PATRIOT AN/MPQ-53'}    {'AN/SPS-67'        }    {'Scanning'}
     20      {'ASR-10SS'         }    {'AR-325 Commander' }    {'Scanning'}


Number of matches: 15
Elapsed time is 0.137725 seconds.
```

Şekil 6.1 Simülasyon Sonuç Ekranı

6.1. Senaryo 1'in Uygulanması

Simülasyon algoritması ile radar sınır koşullarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 20 adet radar rastgele olarak seçilmiştir.

Bu senaryoda kullanılan radar veri setinin olgun olmaması nedeni ile doğru tanımlanan radar sayısının hedeflenenden düşük olması beklenmektedir. İşlem sürelerinin, takip eden ve tarama yapan radarların tahmin edilmesinin kütüphane olgunluğundan etkilenmesi beklenmemektedir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo 6.1'de gösterilmiştir.

Tablo 6.1 Senaryo 1 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	15/20	0,082564	1	19
Destek Vektör Makineleri	14/20	0,105497	2	18
K-En Yakın Komşular	16/20	0,150657	2	18
Topluluk Yöntemleri	18/20	0,091990	4	16
Yapay Sinir Ağları	16/20	0,087819	3	17

Kullanılan tüm makine öğrenmesi algoritmalarının, önceki bölümlerde Şekil 4.5 ve Şekil 4.6'de görüldüğü üzere algoritmaların öğrenme doğruluklarına ve 4.4 bölümündeki ön test sonuçlarına göre beklenen doğruluk değerlerinden daha düşük sonuç verdiği görülmektedir. Algoritmaların toplam ortalama doğruluk oranları %79 olarak hesaplanmıştır.

6.2. Senaryo 2'nin Uygulanması

Simülasyon algoritması ile radar sınır koşullarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 50 adet radar rastgele olarak seçilmiştir.

Bu senaryoda kullanılan radar veri setinin olgun olmaması nedeni ile doğru tanımlanan radar sayısının hedeflenenden düşük olması beklenmektedir. İşlem sürelerinin, takip eden ve tarama yapan radarların tahmin edilmesinin kütüphane olgunluğundan etkilenmesi beklenmemektedir. Ancak Senaryo 1'e göre ortamda daha fazla radar sinyali bulunacağından işlem süresinin değişmesini gözlemlenecektir. Ayrıca doğru tahmin edilen radar sayısının ortamdaki radar sinyali sayısından etkilenip etkilenmediği doğruluk oranları ortalaması hesaplanarak değerlendirilecektir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo *6.2*'da gösterilmiştir.

Tablo 6.2 Senaryo 2 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	41/50	0,112507	3	47
Destek Vektör Makineleri	37/50	0,121525	7	43
K-En Yakın Komşular	37/50	0,094410	8	42
Topluluk Yöntemleri	42/50	0,120370	9	41
Yapay Sinir Ağları	37/50	0,133820	8	42

Bu senaryoda da daha önceki bölümlerde bahsedilen yüksek doğruluk oranları, tehdit kütüphanesinin yeterince olgunlaşmaması nedeniyle elde edilememiştir. Senaryo 1'de %79 olan ortalama doğruluk oranı bu senaryoda yaklaşık %77,6 olarak hesaplanmıştır. Yüzdelik oranlar arasındaki farkın az olmasından dolayı doğruluk oranları ile ortamdaki radar sayısının arttırılması arasında kesin bir ilişki bu senaryoda tespit edilememiştir.

İşlem sürelerinde ise Senaryo 1'e göre farklar gözlemlenmiştir. Algoritmaların işlem hızları ortalaması 0,1037054 saniyeden 0,1165264 saniyeye çıkmıştır. Ancak buradaki fark da çok az olduğundan Senaryo 3 sonuçları ile tekrar değerlendirilecektir.

6.3. Senaryo 3'ün Uygulanması

Simülasyon algoritması ile radar sınır koşullarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 1000 adet radar rastgele olarak seçilmiştir.

Bu senaryoda kullanılan radar veri setinin olgun olmaması nedeni ile ilk iki senaryoda olduğu gibi doğru tanımlanan radar sayısının hedeflenenden düşük olması beklenmektedir. Ancak ilk iki senaryoya göre ortamdaki radar sinyali sayısının dikkat çekici şekilde işlem süresini değiştirmesi beklenmektedir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo 6.3'da gösterilmiştir.

Tablo 6.3 Senaryo 3 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	794/1000	0,114818	148	852
Destek Vektör Makineleri	706/1000	0,176817	159	841
K-En Yakın Komşular	742/1000	0,154316	168	832
Topluluk Yöntemleri	775/1000	0,176561	156	844
Yapay Sinir Ağları	672/1000	0,114712	138	862

Ortamdaki radar sinyallerinin artışı makine öğrenmesi algoritmalarını benzer sinyal parametrelerini ayırt etmekte zorlamış ve önceki senaryolara göre %5-6 arasında daha düşük performans göstermesine neden olmuştur. Tehdit kütüphanesinin ilk iki senaryo gibi olgun olmaması ve yüksek sayıda girdi alınması ile bu senaryoda %73,7 ortalama doğruluk oranı hesaplanmıştır.

Ayrıca işlem süreleri ortalama 0,1474448 saniye olarak hesaplanmış ve gerçek uygulamalarda fark edilemeyecek olsa da süre artışı gözlenmiştir.

6.4. Senaryo 4'ün Uygulanması

Simülasyon algoritması ile radarların çalışabildiği parametre aralıklarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 20 adet radar rastgele olarak seçilmiştir.

Bu senaryoda 4.4 bölümündeki ön test sonuçlarında olduğu gibi beklenen doğruluk değerlerinin yüksek olması ve nadiren yanlış tanımlama yapması beklenmektedir. Kütüphane olgunluğunun yüksek olması ve radar sinyallerinin ara çözünürlüklerinin de tanımlanması ile tehdit kütüphanesi Tablo *5.2*'de örneklendiği gibi optimize edilmiş haldedir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo 6.4'de gösterilmiştir.

Tablo 6.4 Senaryo 4 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	19/20	0,096975	4	16
Destek Vektör Makineleri	20/20	0,152183	3	17
K-En Yakın Komşular	19/20	0,117276	3	17
Topluluk Yöntemleri	19/20	0,112162	4	16
Yapay Sinir Ağları	20/20	0,098098	3	17

Darbe tanımlayıcı kelimelerin radarların tüm çalışma aralıklarını kapsaması ile makine öğrenmesi algoritma modellerinin en iyi performansları elde edilmiştir. Bu senaryoda %97 tahmin doğruluk oranı elde edilmiş ve modellerin ön testlerindeki performans simülasyon algoritmasında da doğrulanmıştır. Senaryoda kullanılan modellerin işlem süresi ortalaması 0,1153388 saniye olarak hesaplanmıştır.

İşlem süreleri ilk üç senaryodaki farklı darbe tanımlayıcı kelimeler kullanıldığından 4, 5 ve 6. senaryoların işlem süreleri kendi aralarında değerlendirilecektir.

6.5. Senaryo 5'in Uygulanması

Simülasyon algoritması ile radarların çalışabildiği parametre aralıklarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 50 adet radar rastgele olarak seçilmiştir.

Senaryo 4'te olduğu gibi radarların tüm çalışma aralıklarının kapsanarak hazırlanan darbe tanımlayıcı kelimeler kullanılacaktır. Radar sayısının artmasının ilk iki senaryo arasındaki gibi çok küçük performans değişikliklerine yol neden olması beklenmektedir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo 6.5'de gösterilmiştir.

Tablo 6.5 Senaryo 5 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	49/50	0,096800	8	42
Destek Vektör Makineleri	49/50	0,129618	11	39
K-En Yakın Komşular	49/50	0,100349	8	42
Topluluk Yöntemleri	49/50	0,106991	9	41
Yapay Sinir Ağları	49/50	0,098873	11	39

Bu senaryoda ortamdaki radar sayısının artması sonuçları etkilemeyip, tahmin doğruluğu da %98 seviyelerinde hesaplanmıştır. İşlem sürelerinde de anlamlı bir değişiklik gözlenmemiştir. Ancak 4. ve 5. senaryolarda modellerin baz işlem süreleri hakkında bilgi edinilmiştir. Senaryoda kullanılan modellerin işlem süresi ortalaması 0,1065262 saniye olarak hesaplanmıştır.

6.6. Senaryo 6'nın Uygulanması

Simülasyon algoritması ile radarların çalışabildiği parametre aralıklarından oluşturulmuş darbe tanımlayıcı kelimeler bulunan veri setinden 1000 adet radar rastgele olarak seçilmiştir.

Önceki iki senaryoda olduğu gibi radarların tüm çalışma aralıklarının kapsanarak hazırlanan darbe tanımlayıcı kelimeler kullanılacaktır. Radar sayısının önceki iki modele göre aşırı artmasının performans değişikliklerine neden olması beklenmektedir. Tanımlama doğruluğu ve işlem süresinin Senaryo 3'tekine benzer şekilde gerilemesi beklenmektedir.

Yapılan tanımlama ve görev tahmini işlemi sonuçları Tablo *6.6*'de gösterilmiştir.

Tablo 6.6 Senaryo 6 Sonuçları

Algoritma Adı	Doğru Tanımlanan Radar Sayısı	İşlem Süresi (saniye)	Takip Eden Radar Sayısı	Tarama Yapan Radar Sayısı
Karar Ağacı	980/1000	0,124225	178	822
Destek Vektör Makineleri	982/1000	0,188115	181	819
K-En Yakın Komşular	984/1000	0,132541	173	827
Topluluk Yöntemleri	981/1000	0,138698	172	828
Yapay Sinir Ağları	984/1000	0,118830	175	825

Bu senaryoda beklendiği üzere tüm makine öğrenmesi algoritma modellerinde işlem sürelerinde artış görüldü. Senaryonun işlem süresi ortalaması 0,1404818 saniye olarak hesaplanmıştır.

İlk üç senaryoda gözlenen tahmin doğruluğunun düşmesi, son üç senaryoda gözlenmemiştir. Bu senaryonun ortalama tahmin doğruluğu %98,2 olarak hesaplanmıştır. Bu durum da darbe tanımlayıcı kelimelerin son üç senaryo için kapsamlı olarak tanımlanması ile sağlanmıştır.

6.7. Algoritma Modellerinin Karşılaştırılması

Tüm senaryolarda test edilmiş olan tüm makine öğrenmesi algoritma modellerinde elde edilen işlem süresi sonuçları, uygulamalarda karşı tedbir sistemlerine gecikme sağlamadan bilgi verebilecek seviyede olduğu görülmüştür. Bu nedenle de algoritma modellerinin performanslarında en büyük ayırt edici sonuç değeri doğru tanımlanan radar sayısı olarak belirlenmiştir.

Bu kriter üzerinde makine öğrenmesi algoritma modellerinin doğruluk yüzdeleri Tablo 6.7'te gösterilmiştir.

Tablo 6.7 Doğru Tanımlanan Radar Sayısı Kriterinin Yüzdelik Sonuçları

Senaryo	Radar Sayısı	Karar Ağacı	Destek Vektör Makineleri	K-En Yakın Komşular	Topluluk Yöntemleri	Yapay Sinir Ağları
1	20	%74	%70	%80	%90	%80
2	50	%82	%74	%74	%84	%74
3	1000	%79,4	%70,6	%74,2	%77,5	%67,2
4	20	%95	%100	%95	%95	%100
5	50	%98	%98	%98	%98	%98
6	1000	%98,4	%98,2	%98,4	%98,1	%98,4

Bu tabloda hem örnekleme sayısının yeterli olmasından hem de hedeflenen doğruluk oranlarına erişildiğinden çalışmanın son çıktısı ve sonucu 6. Senaryo sonuçları olarak değerlendirilmektedir. Bu senaryoda diğer senaryolara göre hem tehdit kütüphanesi olgunluğu hem de aynı anda ortamda bulunan radar sinyal yoğunluğu göz önüne alındığında diğer senaryolara göre daha gerçekçi ve modellerin sınırlarının zorlandığı bir senaryo olduğu görülmektedir. Buna rağmen modeller %98'lerin üzerinde radar tahmin doğruluk oranı sağlamış ve modellerin kurulmasında kullanılan makine öğrenmesi algoritmalarının bu problemde kullanılabilirliği doğrulanmıştır.

7. DEĞERLENDİRMELER VE SONUÇ

Elektronik harp kavramı ile ilgili çalışmalar incelenmiş, genel kavramlara tezde yer verilip, çalışma süresince kullanılacak kavramlar ile ilgili detaylı bilgi verilmiştir. Elektronik harp konusunda gerçekleştirilen yenilikler arasında ayrıştırma, etiketleme ve tanımlama algoritmalarının makine öğrenmesi algoritmaları ile yapılandırılması konusunda yenilikçi yaklaşımlar değerlendirilmiştir.

Tezde yapılan çalışmalarda elektronik destek sistemlerinden olan ve elektronik korunma sistemlerine bilgi sağlayan radar ikaz alıcı sistemlerinin radar sinyali tanımlama yöntemleri incelenmiş ve bu problemde kullanılabilecek makine öğrenmesi algoritmaları literatürde araştırılmıştır.

Makine öğrenmesi algoritmaları arasında yapılan araştırmalar ve ön testler sonucu beş adet algoritma ile çalışmaya başlanmış, bu algoritmaların özellikleri açıklanarak simülasyon için modelleri hazırlanmıştır.

Darbeli radar sinyallerinin yapısı gereği tanımlama işlemine en uygun olana sinyal parametreleri literatür araştırmaları ve testler sonucu doğrulanmıştır. Seçilen radarların kullanılacak olan sinyal parametreleri ile darbe tanımlayıcı kelimeler oluşturulmuş ve bunlar tehdit kütüphanesinde tanımlanmıştır.

Elektronik harp kavramlarının açıklandığı kısımlarda radar ikaz alıcı algoritmalarının ön programlama kısmının elektronik harp destek merkezlerinde sinyal istihbaratı kaynaklarından yararlanılarak yapıldığı açıklanmıştı. Makine öğrenmesi algoritmalarının da öğrenme kısmı elektronik harp destek merkezlerinde yapılacağından radar ikaz alıcılardaki iş yükü azaltılmıştır. Makine öğrenmesi algoritmalarında işlem yükünün büyük kısmı öğrenme kısmında olduğundan, simülasyon ortamında bu kısım halihazırda tamamlanmış olarak algoritmalar çalışabilmektedir.

Simülasyon çalışmasında kullanılan tehdit kütüphanesi, parametre değerlerinin birbirine yakın olması ve simüle edilen muharebe ortamında birden fazla benzer görevlerde radarların bulunması ile radar ikaz alıcılar için zorlu bir ortam oluşturmaktadır. Hazırlanan tehdit kütüphaneleri ve makine öğrenmesi algoritmaları ile simülasyon çalışmaları gerçekleştirilmiş, bu çalışmalar sonrasında kullanılan modellerin tanımlama problemine uygun olduğu görülmüştür. Modellerin test edildiği senaryolar arasında değerlendirmeler yapılmış ve gerçeğe en yakın olduğu belirlenen senaryonun sonuçları değerlendirilmiştir. Bu

senaryoda kullanılan beş makine öğrenmesi algoritması ile de yaklaşık 0,1 saniye süren karar mekanizması ile %98'in üzerinde radar tanımlama doğruluk oranı performansı sağlanmış olup, bu algoritmaların doğru yapılandırılması ile radar tanımlama işleminde konvansiyonel algoritmalara güçlü bir alternatif olduğu görülmüştür.

Gelecek çalışmalarda yapay sinir ağlarına dayalı tanımlama yöntemleri üzerine çalışmalara devam edip, derin öğrenme yöntemlerinin radar tanımlama problemine uygulanabilirliği araştırılacaktır. Buna ek olarak, tehdit kütüphanelerinin farklı sinyal tipleri de içerecek şekilde geliştirilmesi planlanmaktadır.

KAYNAKLAR

[1] L. Wang, Z. Zhang, W. Zeng, and M. Chen, “Radar emitter identification based on spectral resemblance coefficient,” Journal of Physics: Conference Series, vol. 2242, no. 1, p. 012023, Apr. 2022. doi:10.1088/1742-6596/2242/1/012023

[2] Liu, C., Antypenko, R., Sushko, I., Zakharchenko, O., Wang, J. (2021). Marine distributed radar signal identification and classification based on deep learning. Traitement du Signal, Vol. 38, No. 5, pp. 1541-1548. doi:10.18280/ts.380531

[3] L. Gao, X. Zhang, J. Gao and S. You, "Fusion Image Based Radar Signal Feature Extraction and Modulation Recognition," in IEEE Access, vol. 7, pp. 13135-13148, 2019, doi: 10.1109/ACCESS.2019.2892526.

[4] McCarthy, N. F., Guyot, A., Protat, A., Dowdy, A. J., & McGowan, H. (2020). Tracking pyrometeors with meteorological radar using unsupervised machine learning. Geophysical Research Letters, 47. doi: 10.1029/2019GL084305

[5] Chilson, C., Avery, K., McGovern, A., Bridge, E., Sheldon, D. and Kelly, J. (2019), Automated detection of bird roosts using NEXRAD radar data and Convolutional Neural Networks. Remote Sens Ecol Conserv, 5: 20-32. doi: 10.1002/rse2.92

[6] R. Hernangómez, T. Visentin, L. Servadei, H. Khodabakhshandeh, and S. Stańczak, “Improving radar human activity classification using synthetic data with Image Transformation,” Sensors, vol. 22, no. 4, p. 1519, Feb. 2022. doi:10.3390/s22041519

[7] A. Uthayakumar et al., “Machine learning models for enhanced estimation of soil moisture using wideband radar sensor,” Sensors, vol. 22, no. 15, p. 5810, Aug. 2022. doi:10.3390/s22155810

[8] T. Merembayev, Y. Amirgaliyev, S. Saurov, and W. Wójcik, “Soil salinity classification using machine learning algorithms and radar data in the case from the south of Kazakhstan,” Journal of Ecological Engineering, vol. 23, no. 10, pp. 61–67, Oct. 2022. doi:10.12911/22998993/152281

[9] C. Wolff, “Index on Radar Systems” [Çevrimiçi]. Available: www.radartutorial.eu/19.kartei/ka01.en.html [Erişildi: 27 Mart 2024].

[10] “Defence Equipment Intelligence” [Çevrimiçi]. Available: www.janes.com/osint-capabilities/defence-equipment-intelligence/ [Erişildi: 27 Mart 2024].

[11] Wang, X., Liu, J., Zhang, W. et al. Mathematic principles of interrupted-sampling repeater jamming (ISRJ). SCI CHINA SER F 50, 113–123 (2007). doi:10.1007/s11432-007-2017-y

[12] R. D. Christ and R. L. Wernli, The ROV Manual: A User Guide for Remotely Operated Vehicles. 2014.

[13] Grant, P.M.; Collins, J.H.: 'Introduction to electronic warfare', IEE Proceedings F (Communications, Radar and Signal Processing), 1982, 129, (3), p. 113-132, DOI: 10.1049/ip-f-1.1982.0020

[14] A.G. Pakfiliz, Elektronik Harp, Palme Yayınevi, 2021.

[15] D. Adamy, EW 101: A First Course in Electronic Warfare. Boston: Artech House, 2001.

[16] M. Arik and O. B. Akan, "Enabling cognition on Electronic CounterMeasure systems against next-generation radars," MILCOM 2015 - 2015 IEEE Military Communications Conference, Tampa, FL, USA, 2015, pp. 1103-1108, doi: 10.1109/MILCOM.2015.7357593.

[17] P. Man, C. Ding, W. Ren, and G. Xu, “A specific emitter identification algorithm under zero sample condition based on metric learning,” Remote Sensing, vol. 13, no. 23, p. 4919, Dec. 2021. doi:10.3390/rs13234919

[18] J. Dudczyk, “Radar emission sources identification based on hierarchical agglomerative clustering for large data sets,” Journal of Sensors, vol. 2016, pp. 1–9, 2016. doi:10.1155/2016/1879327

[19] Wang, Jundi & Wang, Xing & Tian, Yuanrong & Chen, Zhenkun & Chen, You. (2022). A Radar Emitter Recognition Mechanism Based on IFS-Tri-Training Classification Processing. Electronics. 11. 1078. 10.3390/electronics11071078.

[20] V. Dinç, “Elektronik Harp Teknikleri”, Yüksek Lisans Tezi, Gazi Üniversitesi, 2010.

[21] W. A. Gee, “Radar warning receiver (RWR) time-coincident pulse data extraction and processing,” 2012 IEEE Radar Conference, May 2012. doi:10.1109/radar.2012.6212238

[22] Mishra, Kumar Vijay. (2012). Frequency diversity wideband digital receiver and signal processor for solid-state dual-polarimetric weather radars.

[23] Andriesei, Cristian. Etude de topologies de filtres actifs pour des applications en télécommunications.

[24] Baransky, Eliahu & Itzhak, Gal & Shmuel, Idan & Wagner, Noam & Shoshan, Eli & Eldar, Yonina. (2012). A Sub-Nyquist Radar Prototype: Hardware and Algorithms.

[25] Wiley, R. G., 1985. "ELINT: The Interception of Radar Signals", Artech House, Inc.

[26] M. K. Aslan, "Emitter identification techniques in electronic warfare," Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, 2006.

[27] Z. Yang, W. Qiu, H. Sun, and A. Nallanathan, "Robust radar emitter recognition based on the three-dimensional distribution feature and Transfer Learning," Sensors, vol. 16, no. 3, p. 289, Feb. 2016. doi:10.3390/s16030289

[28] Sun, J., Xu, G., Ren, W. and Yan, Z. (2018), Radar emitter classification based on unidimensional convolutional neural network. IET Radar Sonar Navig., 12: 862-867. doi:10.1049/iet-rsn.2017.0547

[29] Shi, Y. and Ji, H. (2014), Kernel canonical correlation analysis for specific radar emitter identification. Electron. Lett., 50: 1318-1320. doi: 10.1049/el.2014.1458

[30] K. Yamada, W. J. Wan Hamat, H. M. Ishak, K. Hashikura, and T. Suzuki, "Detection of anxiety expression from EEG analysis using support Vector Machine," ECTI Transactions on Electrical Engineering, Electronics, and Communications, vol. 17, no. 1, pp. 87–94, Sep. 2019. doi:10.37936/ecti-eec.2019171.215447

[31] V. Eitle and P. Buxmann, "Business analytics for sales pipeline management in the software industry: A machine learning perspective," Proceedings of the Annual Hawaii International Conference on System Sciences, 2019. doi:10.24251/hicss.2019.125

[32] C. Camara et al., "Non-linear dynamical analysis of resting tremor for demand-driven deep brain stimulation," Sensors, vol. 19, no. 11, p. 2507, May 2019. doi:10.3390/s19112507

[33] S. Song, Z. Zhan, Z. Long, J. Zhang, and L. Yao, “Comparative study of SVM methods combined with voxel selection for object category classification on fMRI Data,” PLoS ONE, vol. 6, no. 2, Feb. 2011. doi:10.1371/journal.pone.0017191

[34] N. Roberto et al., “A support vector machine Hydrometeor classification algorithm for dual-polarization radar,” Atmosphere, vol. 8, no. 8, p. 134, Jul. 2017. doi:10.3390/atmos8080134

[35] J. E. Ball, "Low signal-to-noise ratio radar target detection using Linear Support Vector Machines (L-SVM)," 2014 IEEE Radar Conference, Cincinnati, OH, USA, 2014, pp. 1291-1294, doi: 10.1109/RADAR.2014.6875798.

[36] W. Zhang, X. Chen, Y. Liu and Q. Xi, "A Distributed Storage and Computation k-Nearest Neighbor Algorithm Based Cloud-Edge Computing for Cyber-Physical-Social Systems," in IEEE Access, vol. 8, pp. 50118-50130, 2020, doi: 10.1109/ACCESS.2020.2974764.

[37] A. Coluccia, A. Fascista, and G. Ricci, “A K-nearest neighbors approach to the design of radar detectors,” Signal Processing, vol. 174, p. 107609, Sep. 2020. doi:10.1016/j.sigpro.2020.107609

[38] S. R. Safavian and D. Landgrebe, "A survey of decision tree classifier methodology," in IEEE Transactions on Systems, Man, and Cybernetics, vol. 21, no. 3, pp. 660-674, May-June 1991, doi: 10.1109/21.97458.

[39] A. Young, Machine learning algorithms for identification of low signal-to-noise ratio radar signals. doi:10.22215/etd/2021-14746

[40] A. Lin, Z. Ma, Z. Huang, Y. Xia and W. Yu, "Unknown Radar Waveform Recognition Based on Transferred Deep Learning," in IEEE Access, vol. 8, pp. 184793-184807, 2020, doi: 10.1109/ACCESS.2020.3029192.

[41] Yamashita, R., Nishio, M., Do, R.K.G. et al. Convolutional neural networks: an overview and application in radiology. Insights Imaging 9, 611–629 (2018). doi:10.1007/s13244-018-0639-9

[42] Karas, Peter & Kozak, Š. Kozák. (2018). Highly nonlinear process model using optimal artificial neural network. 1-7. 10.1109/CYBERI.2018.8337548.

[43] M. Codo and M. A. Rico-Ramirez, “Ensemble Radar-Based Rainfall Forecasts for Urban Hydrological Applications”, Geosciences, vol. 8, no. 8, p. 297, Aug. 2018. doi:10.3390/geosciences8080297

[44] G.-H. Lee, J. Jo, and C. H. Park, “Jamming Prediction for Radar Signals Using Machine Learning Methods”, Secur. Communication Netw., vol. 2020, pp. 1–9, Jan. 2020. doi:10.1155/2020/2151570

[45] H. Wang, D. Yu, and Y. Wu, “Analysis of LFM-waveform Libraries for Cognitive Tracking Maneuvering Targets”, MATEC Web Conf., vol. 59, p. 07004, 2016. doi:10.1051/matecconf/20165907004

[46] H.-T. XIE et al., “Simulation of detection effectiveness of Airborne Early Warning radar,” Proceedings of the 3rd Annual International Conference on Electronics, Electrical Engineering and Information Science (EEEIS 2017), 2017. doi:10.2991/eeeis-17.2017.48

[47] X. Song, P. Willett, S. Zhou and P. B. Luh, "The MIMO Radar and Jammer Games," in IEEE Transactions on Signal Processing, vol. 60, no. 2, pp. 687-699, Feb. 2012, doi: 10.1109/TSP.2011.2169251.

[48] Al-Ssulami, Abdulrakeeb & Alsorori, Randh & Azmi, Aqil & Aboalsamh, Hatim. (2023). Improving Coronary Heart Disease Prediction Through Machine Learning and an Innovative Data Augmentation Technique. Cognitive Computation. 15. 1-16. 10.1007/s12559-023-10151-6.

[49] M. Hadzima-Nyarko and S. H. Trinh, “Prediction of compressive strength of concrete at high heating conditions by using artificial neural network-based Bayesian regularization”, J. Sci. Transport Technol., vol. 2, no. 1, pp. 9–21, Feb. 2022. doi:10.58845/jstt.utt.2022.en.2.1.9-21

[50] G. Zhang, J. Yin, S. Zhang and L. Cheng, "Regularization based ordering for ensemble pruning," 2011 Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD), Shanghai, 2011, pp. 1325-1329, doi: 10.1109/FSKD.2011.6019643.