



**EVRIŖİMLİ SİNİR AĞI KULLANARAK DENGESİZ DOPPLER RADAR
VERİSİNDE HEDEF SINIFLANDIRMA**

Muhammed ERDOĞAN

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

EVRIŞİMLİ SİNİR AĞI KULLANARAK DENGESİZ DOPPLER RADAR VERİSİNDE HEDEF SINIFLANDIRMA

(Yüksek Lisans Tezi)

Muhammed ERDOĞAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2023

ÖZET

Kritik öneme sahip askeri ve sivil yerleşkelerin korunması geçmişte olduğu gibi günümüzde de önemini korumaktadır. Bu amaçla, çeşitli sensörler barındıran sistemler geliştirilmektedir. Sensörlerin sağladığı verilerden bilginin elde edilmesi de donanımların en verimli şekilde kullanılması açısından önemlidir. Radar sistemleri keşif, gözetleme ve tespit amacıyla sıklıkla kullanılmaktadır. Literatürdeki radar verisi ile makine öğrenmesi tabanlı yaklaşımlarla hedef sınıflandırma yapılan çalışmalar incelendiğinde radar tiplerinin dört sınıfa ayrıldığı görülebilmektedir. Bunlar, doppler radarları, SAR, pasif radarlar ve uzun menzil hava savunma radarlarıdır. Doppler etkisini referans alarak geliştirilen radarlar doppler radarı olarak isimlendirilirler. Gerçekleştirilen çalışma kapsamında dengesiz doppler veri seti üzerinde çeşitli deneysel çalışmalar yürütülerek literatürdeki mevcut yöntem ve yaklaşımların yanında, sınıflandırma için gerçekleştirilen aşamalarındaki yöntemler çeşitlendirilerek sınıflandırma performansının artırılması ve literatürdeki çalışmalar ile karşılaştırılarak elde edilen sonuçların değerlendirilmesi amaçlanmaktadır. Bu amaçla halka açık, dengesiz bir veri seti kullanılarak radar verisinden hedef sınıflandırma yapılmaktadır. Literatürde sıklıkla tercih edilen rastgele orman ve SVM algoritmaları ile evrişimli sinir ağı modeli, çeşitli ön işleme adımları ve farklı eğitim yaklaşımları doğrultusunda test edilmektedir. Performans açısından en verimli ön işleme, sınıflandırıcı model ve eğitim yaklaşımının belirlenmesi amaçlanmaktadır. Veri setinin, SMOTE veri ön işleme tekniği kullanılarak dengeli hale getirilen veri seti ile önerilen evrişimli sinir ağı modeli k-kat çapraz doğrulama yaklaşımıyla %99,98 eğitim doğruluğuna ulaşılmaktadır. Test verisi ile elde edilen performans metrikleri de diğer yöntemlere göre başarılı daha başarılı sonuçlar elde etmiştir. Aynı veri seti ile literatürde gerçekleştirilen çalışmalar göz önüne alındığında, önerilen yöntemin literatürdeki diğer yöntemlerle rekabet edebilecek seviyede olduğu söylenebilmektedir.

Bilim Kodu : 92432

Anahtar Kelimeler : Radar, insansız hava aracı, K-Kat, SMOTE, evrişimli sinir ağı

Sayfa Adedi : 61

Danışman : Doç. Dr. Oktay YILDIZ

TARGET CLASSIFICATION IN UNBALANCED DOPPLER RADAR DATA USING CONVOLUTIONAL NEURAL NETWORK

(M. Sc. Thesis)

Muhammed ERDOĞAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2023

ABSTRACT

The protection of critically important military and civil settlements maintains its importance today as it was in the past. For this purpose, systems with various sensors are being developed. Extracting information from the data which is provided by the sensors is also important for the most efficient use of the equipment. Radar systems are frequently used for reconnaissance, surveillance and detection purposes. There are rule-based and machine learning-based methods for the classification of objects detected by radar. In machine learning-based approaches, the characteristics of the target object are learned by the model over time without the need for expert opinion. For this reason, these methods are more advantageous than rule-based methods. The studies on the target classification using the radar data with machine learning-based approaches are examined, it can be seen that the radar types are divided into four categories. These are doppler radars, SAR, passive radars and long-range air defense radars. Radars developed based on the Doppler effect are called Doppler radar. Within the scope of the study, various experimental studies are carried out on the unbalanced Doppler data set, in addition to the existing methods and approaches in the literature, it is aimed to increase the classification performance by diversifying the methods in the stages performed for classification and to evaluate the results obtained by comparing them with the studies in the literature. For this purpose, target classification is made from radar data using a public, unbalanced data set. Random forest and SVM algorithms, which are frequently preferred in the literature, and the convolutional neural network model are tested in line with various preprocessing steps and different training approaches. It is aimed to determine the most efficient preprocessing, classifier model and training approach in terms of performance. 99.98% training accuracy is reached with the proposed convolutional neural network model k-fold cross-validation approach with the data set balanced using the SMOTE data preprocessing technique. Performance metrics obtained with test data also achieved more successful results than other methods. Considering the studies carried out in the literature with the same data set, it can be said that the proposed method is at a level that can compete with other methods in the literature.

Science Code : 92432

Key Words : Radar, unmanned aerial vehicle, K-Fold, SMOTE, convolutional neural network

Page Number : 61

Supervisor : Assoc. Prof. Dr. Oktay YILDIZ

TEŞEKKÜR

Tez hazırlama sürecimin tamamında bilgi ve tecrübeleriyle çalışmalarına yön veren çok değerli danışmanım Doç. Dr. Oktay YILDIZ'a sonsuz şükranlarımı sunarım. Sağladığı imkanlar dolayısıyla ASELSAN A.Ş.'ye teşekkür ederim. Maddi ve manevi desteklerini hiçbir zaman benden esirgemeyen ve her daim yanımda olan aileme teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	ix
ŞEKİLLERİN LİSTESİ	x
RESİMLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
2. RADAR TABANLI SİSTEMLERDE HEDEF SINIFLANDIRMA	7
2.1. Doppler Radarı ile Sınıflandırma	8
2.2. Sentetik Açıklıklı Radarlar ile Sınıflandırma	12
2.3. Uzun Menzilli Hava Savunma Radarları ile Sınıflandırma	15
2.4. Pasif Radarlar ile Sınıflandırma	16
3. RADAR VERİSİ İLE HEDEF SINIFLANDIRMADA KULLANILAN MATERİYAL VE YÖNTEMLER.....	19
3.1. Makine Öğrenmesi Algoritmaları	20
3.1.1. Karar ağacı	20
3.1.2. Rastgele orman	22
3.1.3. Destek Vektör Makineleri	23
3.2. Sinir Ağları	25
3.2.1. Algılayıcı.....	26
3.2.2. Çok katmanlı algılayıcı	26

Sayfa

3.2.3. Derin öğrenme modelleri	27
3.2.4. Öznitelik çıkarımı	29
3.2.5. Veri normalizasyonu	30
3.2.6. Sınıf yönünden veri setini dengeleme yöntemleri	30
3.2.7. SMOTE sentetik azınlık aşırı örnekleme tekniği	31
3.2.8. Sınıflandırma performansının ölçülmesi	32
4. DENEYSEL ÇALIŞMA VE ELDE EDİLEN SONUÇLAR	37
4.1. Makine Öğrenmesi Tabanlı Modeller	38
4.1.1. Rastgele orman	38
4.1.2. Destek vektör makineleri	40
4.2. Derin Öğrenme Tabanlı Modeller	43
4.2.1. Evrişimli sinir ağları	43
4.2.2. Eğitim test et tabanlı test yaklaşımı	45
4.2.3. K-Kat çapraz doğrulama	46
5. SONUÇ VE ÖNERİLER	51
KAYNAKLAR	55
ÖZGEÇMİŞ	61

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Radar tabanlı sistemlerde hedef sınıflandırma üzerine yapılan çalışmalar	2
Çizelge 3.1. İki sınıflı karmaşıklık matrisi	34
Çizelge 4.1. Rastgele orman algoritmasında ağaç sayısına bağlı olarak doğruluk oranındaki değişim çizelgesi	39
Çizelge 4.2. Rastgele orman algoritmasının tahmini sonucu elde edilen performans değerleri	39
Çizelge 4.3. SVM algoritması ile gerçekleştirilen eğitime ait performans analizleri	43
Çizelge 4.4. Eğitim test et yaklaşımlı CNN modelinin eğitime ait performans analizleri	46
Çizelge 4.5. 5-Kat çapraz doğrulama sonucunda tüm katlara ait elde edilen değerler .	48
Çizelge 4.6. K-kat çapraz doğrulama yaklaşımlı CNN modelinin eğitime ait performans analizleri	49
Çizelge 5.1. Deneysel çalışma kapsamında elde edilen performans metrikleri ve sonuçları	51
Çizelge 5.2. Deneysel çalışmalarda kullanılan veri seti ile literatürde gerçekleştirilen çalışmaların sonuçları ve önerilen sinir ağı modeli ile elde edilen sonuç .	53

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Ham veri ile hedef sınıflandırmanın şematik gösterimi	7
Şekil 2.2. 5 İHA modeline ait sırasıyla; görsel, ölçülen radar verisi spektrogramı, bilgisayar modeli, bilgisayar modelinden elde edilen radar verisinin spektrogramı	10
Şekil 2.3. Üç hedefe ait P-ISAR görüntüsü; a) kargo gemisi 200,63m uzunluk 26,5 m genişlik, b) kargo gemisi 184m uzunluk 27 m genişlik, c) GPS'e sahip gemi 32 m uzunluk 7m genişlik	17
Şekil 2.4. Örneklere uygulanan ön işleme ve öznelik çıkarım aşamaları; girdi, filtreleme sonrası görüntü, doku filtrelemesi sonrası görüntü, yönelimli filtreleme sonrası görüntü, kaynaşmış (fused) nitelik görüntüsü, nihai filtreleme sonrası hedef görüntüsü, nihai hedefin uzunluk görüntüsü	18
Şekil 2.5. Sınıflandırma sonuçları; a) önerilen yönteme ait karmaşıklık matrisi, b) sınıflandırıcı yöntemlerin ARR yönünden karşılaştırılması	18
Şekil 3.1. Rastgele orman algoritması	22
Şekil 3.2. Doğrusal Olarak Ayrılmış İki Sınıfın Grafiksel Gösterimi	24
Şekil 3.3. Temel bir algılayıcının yapısı	26
Şekil 3.4. Klasik bir CNN modelinin yapısı	28
Şekil 3.5. Rastgele alt örnekleme ve rastgele aşırı örnekleme algoritmalarının veri setini dengeli hale getirmesi	32
Şekil 4.1. Örnek doppler verileri; a) araba, b) İHA, c) insanlar	37
Şekil 4.2. Rastgele orman algoritmasında doğruluk oranının ağaç sayısına göre değişim grafiği.....	39
Şekil 4.3. Rastgele orman algoritmasının gerçekleştirdiği tahminler üzerinden elde edilen karmaşıklık matrisi	39
Şekil 4.4. Orijinal veri setinin dağılımı ve SMOTE algoritması ile dengeleme yapıldıktan sonraki dağılım	40
Şekil 4.5. Orijinal veri seti ile SVM algoritmasının tahmini ile elde edilen karmaşıklık matrisi	41
Şekil 4.6. SMOTE algoritması ile dengeli hale getirilmiş veri seti ile SVM algoritmasının tahmini ile elde edilen karmaşıklık matrisi	41
Şekil 4.7. Orijinal veri set ve k-kat çapraz doğrulama yaklaşımı ile eğitilen SVM algoritmasına ait karmaşıklık matrisi	42

Şekil	Sayfa
Şekil 4.8. SMOTE algoritması ile dengelenen veri seti ve k-kat çapraz doğrulama yaklaşımı ile eğitilen SVM algoritmasına ait karmaşıklık matrisi	42
Şekil 4.9. Geliştirilen evrişimli sinir ağının gösterimi	44
Şekil 4.10. Eğitim sonucunda elde edilen kayıp değeri ve doğruluk oranı metrikler	45
Şekil 4.11. Test verisi ile elde edilen karmaşıklık matrisi	46
Şekil 4.12. 5-Kat yaklaşımı ile 20 devir eğitilmiş modele ait kayıp değeri, doğruluk oranı grafiği	47
Şekil 4.13. 5-Kat yaklaşımı ile 50 devir eğitilmiş modele ait a) kayıp değeri, b) doğruluk oranı grafikleri	47
Şekil 4.14. 5-Kat yaklaşımı ile 100 devir eğitilmiş modele ait kayıp değeri, doğruluk oranı	47
Şekil 4.15. K-kat çapraz doğrulama yaklaşımılı CNN modeline ait test verisi ile elde edilen karmaşıklık matrisi	48
Şekil 4.16. Rastgele seçilmiş 15 örneğe ait tahmin sonuçları	49

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 2.1. MSTAR veri setindeki hedeflerin görselleri ve radar yansıması görüntüleri	8
Resim 2.2. Örnek SAR görüntüleri ve BIMF çıktıları.....	13
Resim 2.3. Örnek a) SAR görüntüsü, b) elde edilen parlaklık matrisi	14
Resim 2.4. Önişleme sonrası sınıflandırılan nesnelere ait görseller a) kargo gemisi, b) rüzgâr türbini, c) tanker gemisi, d) liman, e) petrol platformu.....	15

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
2D2PCA	2-directional 2-dimensional PCA
ARR	Average recognition rates
AFRL	Air force research laboratory
BEMD	Bidimensional empirical mode decomposition
BIMF	Bidimensional intrinsic mode function
CFAR	Constant false alarm rate
CNN	Convolutional neural network
DARPA	Defense advanced research projects agency
EMD	Empirical mode decomposition
FFT	Fast fourier transform
GN	Gerçek negatif
GP	Gerçek pozitif
ISAR	Inverse SAR
İHA	İnsansız hava aracı
k-NN	k-nearest neighbor
JSR	Joint sparse representation
MSTAR	Moving and stationary target acquisition and recognition
MLP	Multi layer perceptron
PCA	Principal component analysis
RCS	Radar cross section
SAR	Synthetic aperture radar
SMOTE	Synthetic minority oversampling technique
SVM	Support vector machine
STFT	Short time fourier transform
YN	Yanlış negatif
YP	Yanlış pozitif

1. GİRİŞ

Askeri veya sivil olarak kritik konumdaki tesis ve yerleşkeler günümüz şartların birçok yönden tehdit altındadır. Bu tür yerleşkelerin korunmasında çeşitli keşif ve gözetleme sistemleri kullanılmaktadır. Bu sistemler çeşitli elektro optik ve radar sistemlerinden oluşmaktadırlar. Radarlar bu tür sistemlerde olası hedeflerin algılanması ve kullanıcının uyarılması açısından kritik öneme sahiptir. Kullandıkları teknikler ve amaçlarına göre ayrılan radarlar cisimlerden yansıyan radyo dalgalarını algılayarak nesne tespiti yapmaktadırlar. Radarın nesneleri tespit etmesi pratikte tek başına yeterli değildir. Çünkü radar tarafından tespit edilen nesnelerin küçük bir bölümü hedef kümesinde olup, hayatın olağan akışı içerisinde bulunan birçok nesne (otomobil, insan ve insanlar topluluğu, hayvanlar vb.) radar tarafından algılanmaktadır. Bu sebeple radar tarafından algılanan nesnelerin sınıflandırılması da bir o kadar önemlidir. Tespit edilen nesneler, mevcut veriler ışığında çeşitli yöntemlerle sınıflandırılmaktadırlar. Hedeflerin sınıflandırılması; operatörün algısını artırmak, kritik durumların tespiti, sistemsel alarmların oluşturulması vb. durumlar için önem arz etmektedir.

Tezin amacı ve kapsamı

Nesnelerin sınıflandırılmasında kural tabanlı ve makine öğrenmesi tabanlı nesne sınıflandırma yaklaşımları öne çıkmaktadır. Kural tabanlı hedef sınıflandırma yaklaşımları deterministik olarak hedeflerin sınıflandırılması için oluşturulan kural setleri dahilinde sınıflandırma yapan yöntemlerdir. Bu tür yöntemler mevcut hedef listeleri göz önüne alınarak uzmanlar tarafından hazırlanmış kurallardır ve olası hedefleri göz ardı etmemek için yüksek yanlış alarm oranına sahiptir. Makine öğrenmesi tabanlı sınıflandırma yaklaşımlarında ise mevcut veri seti içerisindeki hedef sınıfları sınıflandırma algoritmalarına öğretilerek hedefe ait veriler ile sınıflandırılması hedeflenmektedir. Çizelge 1.1.'de radar verisi kullanılarak makine öğrenmesi tabanlı yöntemlerle sınıflandırma yapılan çalışmalar verilmektedir.

Radarlar, nesneden yansıyan radyo dalgalarının algılanması ile nesnenin tespit edilmesini, nesnenin hızının, yöneliminin ve konumunun belirlenmesini sağlayan cihazlardır. İhtiyaca göre farklı boyutlarda, menzillerde tasarlanmaktadırlar. Ürettikleri sinyallerin dalga boyları değiştirilerek ve baz aldıkları teknolojiler geliştirilerek, hedef kümesi içinde yer alan nesnenin fark edilmesi ve nesneye ait belirlenen karakteristiklerin artırılması

amaçlanmaktadır. Çok çeşitli radar tipleri bulunmasının yanında özellikle makine öğrenmesi tabanlı yöntemlerin başvurulduğu sistemlerde kullanılan radarlar genel olarak, doppler radarları, SAR, uzun menzil radarlar ve pasif radarlar olarak sınıflandırılırlar.

Çizelge 1.1. Radar tabanlı sistemlerde hedef sınıflandırma üzerine yapılan çalışmalar

Çalışma	Radar Sistemi	Çalışmanın Amacı
Luo, Poslad ve Bodanese (2019)	BumbleBee Radar (Mikro-Doppler)	Nesne Sınıflandırma: İnsan, Köpek, Köpek ve İnsan, Nesne Yok. İnsan Aktivitesi Sınıflandırma: Yürüme, Koşma. İnsan Sayısına göre Sınıflandırma: 1, 2, 3, 4 İnsan Tahmini konum Sınıflandırma: 1-3 m, 3-5m, 5-8m
Angelov, Robetson, Smith ve Fioranelli (2018)	TEF810X (Mikro-Doppler)	Nesne Sınıflandırma: 1 Yürüten İnsan, Hız Değiştiren Araba, Sekiz Çizen Bisiklet, 2 Yürüten İnsan
Muo, Chen, Su ve Guan (2019)	Simülör (Mikro-Doppler)	Hareket Sınıflandırma: Sabit Hızlı, Hızlanan, Yavaşlayan, Hareket Yok
Oh, Guo, Wan ve Lin (2018)	X-band CW radar (Mikro Doppler)	11 model mini-İHA Sınıflandırma
Torvik, Olsena ve Griffiths (2016)	Uzun Menzil Hava Savunma Radarı (S Band)	Geniş Kanatlı Kuşların ve Sabit Kanatlı İHA'ların Ayırıştırılması
Will, Vaishnav, chakraborty ve Santra (2019)	24 GHz ISM Band Radar (Mikro doppler)	Nesne Sınıflandırma: Tek sınıf sınıflandırıcı ile insanların tespiti ve takibi
Huizing, ve diğerleri (2019)	9,5 GHz Sürekli dalgalı Radar (Mikro Doppler)	5 model mini-İHA sınıflandırma, Bilinmeyen Hedef tanımlama, Gürültülü Spektrogram Temizleme, Spektrogram Üretimi için Model Eğitimi
Chang, You, ve Cao (2019)	SAR	Hedef Sınıflandırma
Chen, Wang, Xu ve Jin (2016)	SAR	10 Sınıflı Hedef Sınıflandırma
Manno-Kovacs, Giusti, Verizzi ve Kovacs (2019)	Pasif ISAR	12 Sınıflı Hedef Sınıflandırma

Çizelge 1.1. (Devam) Radar tabanlı sistemlerde hedef sınıflandırma üzerine yapılan çalışmalar

Zhu, Wang ve Leung (2020)	SAR	10 yer hedefini Hedef Sınıflandırma
Wang, Zheng, Leia ve Bai (2018)	SAR	10 Sınıflı Hedef Sınıflandırma
Bentes, Velotto ve Tings (2018)	SAR	5 deniz platformunu sınıflandırma
Fioranelli, Ritchie, Gürbüz ve Griffiths (2017)	2.4 GHz NetRad Multistatik Radar Sistemi (Mikro Doppler)	Silahlı ve silahsız insanın sınıflandırılması, insanların yürüyüş karakteristiklerinin belirlenmesi
Kim ve Moon (2016)	7.25 GHz Doppler Radar	İnsan tespiti ve aktivite sınıflandırma
Jokanovic ve Amin (2017)	Sürekli Dalgalı Radar (Mikro Doppler)	Düşen İnsan Hareketi Tespiti

Doppler etkisini referans alarak geliştirilen radarlar doppler radarı olarak isimlendirilirler. Doppler etkisi, herhangi bir dalga üretici nesnenin hareket etmesi sonucu algılanan frekans ile gerçek frekans arasındaki oluşan sapmadır. Bu sapmanın ölçülmesi sonucunda nesnenin hızı hesaplanmaktadır. Doppler etkisinden faydalanılarak geliştirilen doppler radarları, nesne konumu tespiti yapmasının yanında tespit edilen nesnenin hızını da hesaplamaktadır. Sentetik açıklıklı radar, hareketli platform üzerinde bulunan ve hareket halinde toplanan verileri elektronik ortamda birleştirerek daha büyük donanımların tek seferde toplayacağı verileri toplayan radar türüdür. Sentetik açıklıklı radar, yeryüzü şekilleri ve beşerî yapılar gibi üç boyutlu yapıların, iki boyutlu resimlerini veya üç boyutları modellerini oluşturmak için kullanılırlar. Genellikle hava araçları veya uyduların üzerine monte edilmektedir. SAR verisi yansıdığı yüzey hakkında ve geometrisi hakkında bilgiler içermektedir.

Uzun menzil hava savunma radarları uzak mesafedeki hava hedeflerinin tespiti ve takibi için özel olarak geliştirilmiş radarlardır. Uzun menzilli hava savunma radarları, büyük hacimli hava platformlarının gözetlenmesi için anahtar sensörlerdir. Bununla birlikte düşük irtifa, hız ve radar kesit alanı (RCS) insanlı uçaklara kıyasla küçük hedeflerin tespitini zorlaştıran faktörlerdir. Sınıfın modern radarları, önemli mesafelerde fiziksel olarak küçük veya

karakteristik yönünden RCS değeri azaltılmış hedeflerin tespiti için geliştirilmiş hassas sensörlerdir [1].

Pasif radarlar sinyal kaynağı olmayan, yalnızca alıcı bulunduran ve bu alıcı ile ortamdaki radyo dalgalarını işleyen radarlardır. Pasif radarlar, aktif radarlardan farklı olarak hedeften yansıması için radyo sinyali yaymazlar. Bunun yerine hedeften yansıyan başka donanımlara ait radyo dalgalarını veya nesnenin kendisinin ürettiği radyo dalgalarını işleyerek nesne hakkında veri üretmektedirler. Düşük maliyetli olmaları, sinyal yaymamaları sebebiyle görünürlüklerinin az olması ve radyo dalgası kirliliğe oluşturmamaları sebebiyle askeri ve sivil alanda sıklıkla başvurulmuş teknolojilerdendir [2].

Radar verisi ile hedef sınıflandırma günümüzde sektörün ve araştırmacıların ilgisini çeken bir alandır. Literatürdeki mevcut yöntemlerin yanında yeni yaklaşımların ortaya konulması, verimliliğin artırılması ve konu üzerindeki zorlayıcı noktaların çözülmesi için çalışmalar devam etmektedir.

Çalışma kapsamında dengesiz doppler veri seti üzerinde çeşitli deneysel çalışmalar yürütülerek literatürdeki mevcut yöntem ve yaklaşımların yanında, sınıflandırma için gerçekleştirilen aşamalarındaki yöntemler çeşitlendirilerek sınıflandırma performansının artırılması ve literatürdeki çalışmalar ile karşılaştırılarak elde edilen sonuçların değerlendirilmesi amaçlanmaktadır.

Araştırmanın önemi

Literatürdeki mevcut radar verisi ile sınıflandırma çalışmalarında ihtiyaç doğrultusunda çeşitli hedef sınıflandırma yapıları kurulmaktadır. Örneğin maliyet etkin çözümler ortaya koymak amacıyla ham veri üzerinde fazla ön işleme adımı uygulanmaması ve nispeten işlem maliyeti daha düşük sınıflandırıcı algoritmalar ile yüksek hedef sınıflandırma performansı elde edilmek istenmektedir. Başka bir çalışmada ise ham veriden en yüksek verimi alabilmek adına birçok ön işleme adımı uygulanarak çeşitli öznelilikler elde edilerek sınıflandırıcı yapının doğruluğunun olabildiğince artırılması hedeflenmektedir.

İncelenen çalışmalar göz önüne alındığında, verinin elde edildiği radar tipi, radar kullanıldığı sektör, sistemin zaman kritiklik ihtiyacı vb. parametreler doğrultusunda sınıflandırma için kullanılan yöntem ve yaklaşımlar farklılık içermektedir. Bu durum da beraberinde sınırlayıcı etmenlere bağlı olarak üzerinde çalışmayı getirmektedir.


Genel radar verisi ile hedef sınıflandırma konusundan, savunma sektöründeki mevcut doppler radar teknolojileri baz alınarak İHA hedeflerinin derin öğrenme teknikleri ile sınıflandırılması konusu kendi özelinde araştırma, bilgi birikimi ve tecrübe edilmesi gereken bir alandır.

Sınırlılıklar

Tehdit olabilecek sınıf içeren, etiketlenmiş, doppler radar veri setine günümüzde ulaşmak çok mümkün değildir. Askeri ve ticari anlamda değerleri sayılabilecek bu tür veri setleri halka açık olarak fazla bulunmamaktadır. Bu amaçla kullanılacak bir doppler radar veri setinin oluşturulması ise, teknik malzeme, maliyet ve bürokratik süreçler yönünden oldukça zorlayıcıdır. Ölçüm yapılması için uygun altyapının belirlenip oluşturulması da başlı başına operasyonel faaliyettir. Bu sebeple çalışma kapsamında halka açık olarak erişebildiğimiz, literatürde test edilmiş ve hedef setimize en uygun sınıfları içeren bir doppler radar veri seti deneysel çalışmalarda kullanılmaktadır.

2. RADAR TABANLI SİSTEMLERDE HEDEF SINIFLANDIRMA

Radarlar, keşif gözetleme sistemlerinde sıklıkla başvuru alan donanımlardandır. Kullandıkları teknolojiler açısından çeşitli gruplara ayrılmaktadırlar. Radarın elde ettiği verilerin işlenmesi ile nesne sınıflandırma, hedef takibi, aktivite sınıflandırma gibi çalışmalar yapmak mümkündür [3]. Şekil 2.1.'de özetlendiği üzere, radar tarafından üretilen ham veriden veri ön işleme yöntemleriyle öznitelikler elde edilir. Nitelikler verideki hedefe ait ayırt edici özelliklerdir. Elde edilen nitelikler ile sınıflandırıcı algoritma eğitilmektedir. Eğitilen sınıflandırıcı algoritma elde edilen veri sayesinde nesne verisinin sınıfını tahmin etmektedir.




Şekil 2.1. Ham veri ile hedef sınıflandırmanın şematik gösterimi

Veri, belirli kurallar çerçevesinde donanımdan alınan sinyallerdir. Kural tabanlı sistemlerde verinin işlenmesiyle, uzmanlar tarafından belirlenen kurallar dahilinde kullanıcı bilgilendirilir, uyarılır ve harekete geçirilir. Veri içerisindeki fark edilmemiş örüntüler mevcut veriden elde edilebilecek bilgilerdir. Sınıflandırıcı algoritmalar yeterli miktarda veri ile eğitildiklerinde bu kuralları ve örüntüleri öğrenir ve eğitim sonrasında elde edilen verileri işleyerek hedefin sınıflandırılmasını sağlar.

Mevcut halka açık veri setleri incelendiğinde radar verileri donanımın tipine göre farklılık göstermektedir. Örneğin MSTAR, halka açık olan bir SAR veri setidir. SAR veri setleri genellikle MSTAR veri setinde olduğu gibi taranan bölgenin iki boyutlu görüntülerinden oluşur. Görüntü üzerindeki piksel değerleri hedefe ait karakteristik bilgiler içermektedir. Burada radar donanımının yaklaşım açısı, hedefi görüşü gibi etmenler değerlerde değişime sebep olmaktadır. Eğitim aşamasında bu tür parametrelerinde dahil edilmesi modelin başarımını artırmaktadır. Resim 2.1.'de MSTAR veri setindeki bazı sınıflara ait görseller ve radar görüntüleri verilmektedir.

Ön işleme, eğitilecek modelin başarımının artırılması amacıyla veriden en yüksek verimin alınması için uygulanan işlemlerdir. Ham verinin standartlaştırılması, matematiksel ve istatistiksel yöntemlerle işlenmesiyle niteliklerin elde edilmesi, gereksiz ve aykırı verilerin



Resim 2.1. MSTAR veri setindeki hedeflerin görselleri ve radar yansıması görüntüleri

temizlenmesi, sınıflandırıcı modele katkısı olmayan niteliklerin belirlenmesi, veri setinin dengeli hale getirilmesi gibi birçok yöntem ön işleme adımı olarak değerlendirilir. Sınıflandırıcı modelin optimum yapıya ulaşmasından sonra başarımı etkileyen en önemli faktör verinin kalitesidir. Bu sebeple ön işleme adımı oldukça kritiktir.

Sınıflandırma, belirli bir veri setini sınıflara ayırma işlemidir. Sınıflandırmada temel amaç yeni verilerin hangi sınıfa dahil olduğunu belirlemektir. Radar veri setleri ile sınıflandırıcı modellerin eğitilmesi ile nesneler sınıflandırılmaktadır.

Radar verisinin tipi ve sistemin gereksinimleri göz önüne alındığında kullanılan sınıflandırıcı model farklılık göstermektedir. Görüntü tabanlı veri setlerinde çoğunlukla derin öğrenme tabanlı yöntemler tercih edilirken, sayısal nitelikler içeren veri setlerinde ve işlem maliyetinin düşük olması istenen çalışmalarda SVM, k-NN, karar ağacı vb. yöntemler tercih edilmektedir [1, 3- 6].

2.1. Doppler Radarı ile Sınıflandırma

Doppler konsepti ilk olarak 2000 yılında Chen tarafından ortaya atılmıştır [3]. Doppler radarlarının elde ettiği veriler incelendiğinde ve tespit edilen nesneler sınıflara ayrıldığında, sınıfların kendine ait doppler imzaları olduğu görülmektedir. Doppler imzaları, hareket eden nesnelerin periyodik olan kinetik karakteristiklerini yansıtmaktadır. Bu sayede nesneye ait doppler bilgileri ile nesnenin aktivitesi ve sınıfı belirlenebilir [3]. Doppler radarları askeri ve sivil alanlarda sıklıkla kullanılmaktadır [3-7].


Öznitelik çıkarma yöntemleri makine öğrenmesi modelinin eğitimini standartlaştırma ve başarısını artırmak için başvurulan tekniklerdir. Doppler radarından elde edilen verilere uygulanabilen tekniklerden olan STFT kullanılarak nesnenin iki boyutlu zaman sıklık grafiği

oluşturulabilmektedir [3-7]. Bu yöntem ile spektrogramlardan frekansa bağlı olarak görüntü kareleri elde edilmektedir. Görüntü kareleri derlenerek veri setleri oluşturulmaktadır.

Sinyalin niteliklerinin belirlenmesi ve arka plan gürültülerinden kurtulmak amacıyla, spektrogramlar üzerinde boyut azaltımı yapılmaktadır [3]. PCA iyi bilinen öznitelik çıkarım ve boyut azaltma yöntemlerindendir [3, 4]. Bu tekniğin bir türevi olan 2D2PCA, piksellerden oluşan iki boyutlu spektrogramlar üzerinde oldukça etkilidir. 2D2PCA bu sebeple birçok çalışmada kullanılmaktadır [3]. Radar verisinin iki boyutlu hale getirilmesi için STFT kullanılmasının yanında alternatif olarak başka yöntemlerde mevcuttur. Angelov ve diğerleri (2018) çalışmalarında STFT yerine FFT, OS-CFAR algoritması ve kalman filtresinden oluşan bir yapı kullanmaktadırlar. Bu yapının STFT'ye göre özellikle çoklu hedeflerin belirlenmesinde daha etkili olduğu belirtilmektedir. Fioranelli ve diğerleri (2017) çalışmalarında mikro doppler imzalarının karakterize edilirken zaman sıklık analizinin elde edilmesi için Gabor dönüşümü, Wigner-Ville dönüşümü, Cohen'nin zaman sıklık dağılımı ve EMD'nin de zaman sıklık analizi için kullanıldığı ve bu yöntemlerin de etkili olduğu belirtmektedirler.

Doppler verisi analizi ile elde edilen spektrogramlar sayesinde nesnelerin veya nesne hareketlerinin sınıflandırması yapılabilmektedir. Luo ve diğerleri (2019) çalışmalarında SVM, kNN ve CNN algoritmaları, nesne ve hareket sınıflandırma için kullanmaktadırlar. Çalışmadaki sonuçlar incelendiğinde CNN algoritmasının oldukça başarılı olduğu görülmektedir. Ancak CNN algoritması diğerlerine nazaran daha maliyetli olması sebebiyle kendisine alternatif arayışlar çalışmalarda yer bulmaktadır. Luo ve diğerleri (2019) çalışmalarında SVM ve kNN algoritmasının eğitiminde kullanılan verilere 2D2PCA öznitelik çıkarım yönteminin uygulanmasıyla algoritmaların doğruluk oranı oldukça yükselmekte ve CNN algoritmasıyla rekabet edebilecek seviyelere geldiği belirtmektedirler. Spektrogram analizi yapılan diğer çalışmalarda [4, 5] da sınıflandırıcı olarak CNN algoritması ön plana çıkmaktadır. Ayrıca derin öğrenme tabanlı diğer ağ yapıları da (Residual CNN, LSTM destekli RNN) çalışmalarda başvurulan sınıflandırıcı yapılardandır [60-62]. Bu duruma örnek olarak Huizing ve diğerleri (2019) çalışmalarında 5 mini-İHA'ya ait ölçüm sonucunda ve benzetim yöntemiyle elde edilmiş radar spektrogramları ile çeşitli senaryolardaki modelleri eğitmektedirler. Eğitilen modeller çeşitli parametrelere ait CNN ağları ve bir adet LSTM destekli RNN ağıdır. Çalışma kapsamında şekil 2.2.'de görselde verildiği üzere farklı mini-İHA modellerinden radar verileri toplanmakta ve sınıflandırıcı modeller eğitilmektedirler.

Çalışmada aynı mini-İHA'lar bilgisayar ortamında modellenerek simüle edilmekte ve bu modeller üzerinden de radar verileri toplanmaktadır. Çalışmada dikkat çeken nokta, simüle veriler ile eğitilecek bir modelin gerçek radar verisini tahmininde kullanılıp kullanılamayacağıdır. Bu amaç doğrultusunda geliştirilecek modelin, birçok yönden avantaj sağlayacağı belirtilmektedir [7]. Ancak modelin eğitim başarısı incelendiğinde, simülasyon üzerinden elde edilen veri ile eğitilen modellerin başarısı, gerçek veri ile eğitilen sınıflandırıcı modeller karşısında oldukça başarısız olduğu görülmektedir. Bu çalışma sayesinde makine öğrenmesi modellerinin eğitiminde veri kalitesinin modelin eğitiminde ne kadar etkili olduğu ortaya konulmaktadır.



Şekil 2.2. Çalışma [7] kapsamında 5 İHA modeline ait sırasıyla; görsel, ölçülen radar verisi spektrogramı, bilgisayar modeli, bilgisayar modelinden elde edilen radar verisinin spektrogramı

STFT kullanılarak elde edilen spektrogramlar görsel olarak sınıfa ait ayırt edici özellikleri içerisinde barındırmaktadır. Spektrogramlar ile derin öğrenme tabanlı yöntemler eğitilebilmektedir. Buna ek olarak spektrogramlardaki ayırt edici özellikler çeşitli yöntemlerle elde edilebilmektedir. Elde edilen sayısal ve kategorik niteliklerle de derin öğrenme tabanlı yöntemlerin dışındaki sınıflandırıcılar eğitilmekte ve kullanılabilmektedir. Fioranelli ve diğerleri (2017) çalışmalarında bu duruma örnek olarak, STFT ile sınıflara ait doppler verileri spektrogramlar haline getirilmekte ve çeşitli yöntemlerle 12 farklı nitelik (Çizelge 2.3.) elde edilmektedir. Nitelikler ile Naive Bayes, Diagonal-Linear Variant of Discriminant Analysis, k-NN ve karar ağacı sınıflandırıcılarını eğitilmektedir.

Son yıllarda gerçekleştirilen mevcut çalışmalar incelendiğinde doppler radarı ile yapılan çalışmalarda çoğunlukla STFT kullanılarak radar verilerinin spektrogramlarının elde edilmesi amaçlanmaktadır. Ancak bu yöntemle çıkarımda bulunmak için çoğunlukla uzun zaman aralıklı radar verilerine ihtiyaç duyulmaktadır [6]. Dahası, zaman sıklık çözünürlüğündeki kısıtlamalar da STFT tabanlı yöntemleri sınırlamaktadır. Bu sorunlara çözüm olması açısından mikro-doppler radar verisi ile yapılan çalışmalarda STFT tabanlı yöntemlerden farklı olarak mikro-doppler imzalarının analizinde fourier tabanlı olmayan zaman sıklık analizi yöntemleri tercih edilmektedir. Bu amaçla Oh ve diğerleri (2018) çalışmalarında EMD kullanmaktadırlar. Bu yöntem sayesinde elde edilen nitelikler (Çizelge 2.1) görüntü karelerinden farklı olarak sayısal ve kategorik veriler olmaları sebebiyle farklı sınıflandırıcıların kullanılmasına da olanak sağlamaktadır.

Çizelge 2.1. Çalışma [6]'da elde edilen nitelikler

Nitelik Sırası	Nitelik Açıklamaları
1	Sıfırdan Geçiş Sayısı
2	Normalleştirilmiş Sinyal Enerjisi
3	Standart Sapma
4	Entropi
5	İki Birleştirilmiş IMF'nin Entropisi
6	Normalleştirilmiş En Yüksek-Ortalama Farkı
7	İki Frekans Tepesi arası Mesafe
8	Sıfırdan Geçiş Sayısı Oranı

Matematiksel yöntemlerle niteliklerin elde edilmesi ve bu niteliklerle sınıflandırıcıların eğitilmesi üzerine yapılan çalışmalarda derin öğrenme tabanlı yöntemlerin yanında SVM gibi, derin öğrenme tabanlı yöntemlere nazaran, daha az maliyetli sınıflandırıcılar da kullanılmaktadır. Oh ve diğerleri (2018) çalışmalarında çizelge 2.1.'de verilen nitelikler ile

SVM algoritması eğitmekte ve 11 farklı İHA türü sınıflandırmaktadırlar. Will ve diğerleri de (2019) çalışmalarında elde edilen 10 adet nitelik ile nesne sınıflandırma için SVM algoritması eğitmektedir. Eğitim sonucunda insanlara ait örneklemeleri öğrenen sınıflandırıcı model, insanları diğer nesnelerden ayırt edebilir hale getirilmektedir.

Çizelge 2.2. Çalışma [8]'de spektrogramlardan elde edilen nitelikler


Nitelik Sırası	Nitelik Açıklamaları
1	Doppler Bant Genişliği Orta Noktası
2	Doppler Ağırlık Merkezi Orta Noktası
3	Doppler Bant Genişliği Standart Sapması
4	Doppler Ağırlık Merkezi Standart Sapması
5	İlk Tekil Sağ Vektör Standart Sapması
6	İlk Tekil Sağ Vektör Orta Noktası
7	İlk Tekil Sol Vektör Standart Sapması
8	İlk Tekil Sol Vektör Orta Noktası
9	U Matris Piksellerinin Standart Sapması
10	U Matris Köşegeninin Orta Noktası
11	U Matris Piksellerinin Toplamı
12	V Matris Piksellerinin Toplamı

2.2. Sentetik Açıklıklı Radarlar ile Sınıflandırma

Taranan bölgenin verisinin görüntü formatında elde edilmesi ile çeşitli görüntü analizlerinin yapılabilmesi sonucunda keşif, gözetleme ve sınıflandırma konularında SAR verileri oldukça başarılıdır. Halka açık birçok veri setinin bulunmasının yanında MSTAR veri seti bu türdeki en bilinen veri setlerindendir. MSTAR programı, DARPA ve AFRL tarafından

ortaklaşa desteklenen bir programdır. Veri seti, çeşitli askeri ve sivil araçlardan oluşan yer hedeflerinin, farklı açılardan ve farklı radar alçalış açılardan elde edilen binlerce SAR görüntüsünün toplanmasıyla oluşturulmuştur. Veri setinin yalnızca küçük bir bölümü halka açıktır [10].


MSTAR veri setinde olduğu gibi SAR üzerinde elde edilen veriler çoğunlukla iki boyutlu görsellerden oluşmaktadır. Bu sebeple hedef sınıflandırma çalışmalarında literatürdeki görsel üzerinden hedef sınıflandırma yöntemlerine ağırlık verilmektedir [10-14]. Örneğin Chang ve diğerleri (2019) çalışmalarında MSTAR veri setindeki sınıflandırılmış hedef görsellerine BEMD uygulanarak SAR görüntülerindeki ayrıntıların tanımlanması için BIMF'ler oluşturulmaktadır. BEMD, durağan olmayan sinyallerin analizi için etkili olan EMD'nin iki boyutlu sinyaller özelinde kullanılması için sunulan, görüntü bölümleme, birleştirme ve sıkıştırma vb. işlemler için başvurulmuş bir yöntemdir. Chang ve diğerleri (2019) çalışmaları kapsamında SAR görüntülerine BEMD uygulanarak elde edilen BIMF görüntüleri resim 2.2'de verilmektedir.



Resim 2.2. Çalışma [11]'de verilen örnek SAR görüntüleri ve BIMF çıktıları

Bu çalışmada, SAR görüntüleri ve görüntülerden elde edilen BIMF görüntüleri ile JSR (Joint Sparse Representation) algoritması eğitilmektedir. MSTAR veri seti üzerindeki deneysel sonuçlar, bu algoritma ile farklı çalışma koşulları altında geçerliliğini göstermektedir. Bazı


temel algoritmalarla karşılaştırıldığında, bu algoritmanın üstünlüğü ayrıca doğrulanmaktadır. Chen ve diğerleri (2016) çalışmalarında MSTAR veri seti üzerinden hedef sınıflandırma üzerine çalışma yapmaktadırlar. Bu çalışmada otomatik nitelik çıkarımı için özellik haritası (feature map) tekniği kullanılmaktadır. Bu teknik ile iki boyutlu matris üzerinde daha küçük iki boyutlu matris ile taranarak öznitelikleri elde etmek amaçlanmaktadır. Bu teknik sayesinde görece az örneklem içeren veri setlerindeki örnek sayısı da artırılmaktadır. Elde edilen matrisler ile CNN modeli eğitilerek 10 sınıflı veri setinin aşırı öğrenme olmadan sınıflandırılması sağlanmaktadır. Zhu ve diğerleri (2020) çalışmalarında radar görüntüsünün parlaklık bilgisini kullanarak geleneksel olanlardan oldukça farklı olan yeni bir SAR hedef sınıflandırma yöntemini tanıtmaktadırlar. Çalışmada, mevcut çalışmaların birçoğunda ham radar verisinin sinir ağına verilerek birkaç adımda sınıflandırma sonuçlarının alınmasından ibaret olduğu belirtilmektedir. Ancak SAR verisinin sınırlı olması ve verideki benek gürültülerinin var olması sebebiyle hedefin kusursuz olarak sınıflandırılmasında büyük bir problem olarak görülmektedir. Bu sorunu çözmek için çalışmada, her SAR görüntüsünün parlaklık verisi çıkarılmaktadır ve bu da benek gürültüsünü önemli ölçüde azaltmaktadır [12]. Resim 2.3.'te SAR görüntüsü ve bu görüntüden elde edilen parlaklık verisi verilmektedir. Çalışma kapsamında MSTAR veri setindeki SAR görüntülerinden parlaklık matrisleri elde edilmekte ve bu veriler ile CNN modeli eğitilmektedir. Eğitim sonucunda model 100%'e yakın doğruluğa ulaşmıştır. Çalışmada, parlaklık verilerinin etkinliğini göstermek amacıyla ham veri ile aynı model eğitilerek karşılaştırma yapılmaktadır. Karmaşıklık matrisleri ve iterasyon-doğruluk grafikleri karşılaştırıldığında parlaklık verisi ile eğitilen modelin daha başarılı olduğu görülmektedir.



Resim 2.3. Çalışma [13]'te verilen; a) SAR görüntüsü, b) elde edilen parlaklık matrisi

Wang ve diğerleri (2018) çalışmalarında SAR görüntülerindeki gürültü problemi ve hedef sınıflandırma üzerinde çalışma yapmaktadır. MSTAR veri setindeki örneklerdeki gürültünün azaltılması ve sınıflandırma için iki CNN ağı içeren bir ağ modeli geliştirilmektedir. İlk katmanda gürültüsü azaltılan örneklerle ikinci katmandaki CNN ağı eğitilmektedir. Eğitim sonucunda ortalama %98,06 doğruluğa ulaşılmaktadır.

MSTAR veri setinden başka SAR veri setleri de çalışmalarda kendine yer bulmaktadır. Örneğin Bentes ve diğerleri (2018) çalışmalarında Alman Havacılık ve Uzay Merkezi tarafından işletilen TerraSAR-X uydusundan alınan veriler ile 5 farklı deniz platformunun (kargo gemisi, rüzgâr türbini, tanker gemisi, liman ve petrol platformu) sınıflandırılması üzerine çalışma yapılmaktadır (Resim 2.4.). Çalışmada sınıflandırma için kurulan yapı iki aşamadan oluşuyor. İlk aşamada TerraSAR-X görüntülerindeki hedeflerin tespiti ve merkezileştirilmesi için standart CFAR algoritması kullanılıyor. Bu sayede sınıflandırıcı modellerin performansının artırıldığı belirtiliyor. Ayrıca tespit edilen hedefler orijinal görüntülerden ayrıştırılırken örneklerin görüntü çözünürlükleri sabitlendiği (128x128) için sınıflandırıcı modele vermeye daha uygun veriler elde edilmektedir. Çalışmada dayanak sınıflandırıcı olarak PCA+SVM sınıflandırıcı kullanılmaktadır. Önerilen yöntem olarak ise 4 farklı CNN ağı sunulmaktadır. Sonuçlar incelendiğinde CNN modellerinden biri hariç diğerlerinin dayanak sınıflandırıcıdan daha başarılı olduğu görülmektedir.



Resim 2.4. Önişleme sonrası çalışma [14]'da sınıflandırılan nesnelere ait görseller a) kargo gemisi, b) rüzgâr türbini, c) tanker gemisi, d) liman, e) petrol platformu

2.3. Uzun Menzilli Hava Savunma Radarları ile Sınıflandırma

Uzun menzilli hava savunma radarları kullanım alanından dolayı diğer radar türlerine göre daha az çalışma bulunmaktadır. Torvik ve diğerleri (2016) çalışmalarında uzun menzil hava savunma radarı kullanarak sabit kanatlı İHA'ların geniş kanatlı kuşlardan ayrıştırılması üzerine çalışmaktadırlar. Sabit kanatlı İHA'lar ile geniş kanatlı kuşların uzun menzil hava savunma radarı ile ayırt edilebilmesi polarimetrik parametreler sayesinde mümkün

olmaktadır [1]. Polarimetrik ayrışım parametreleri (çizelge 2.3) ise SAR görüntüsünden hedef sınıflandırma çalışmalarında da kullanılmaktadır [1]. Bu kapsamda çalışmada radar verisi üzerinden polarimetrik nitelikler elde edilmektedir. Elde edilen nitelikler ile k-NN algoritması eğitilerek belirlenen dört sınıfın öğrenilmesi amaçlanmaktadır. Çalışmada, kullanılan sistemin özellikle zaman kritik olduğu ve bu sebeple zamanında tepki vermesinin ihtiyaç olduğu belirtilmektedir. Daha başarılı ancak maliyetli algoritmalar yerine k-NN algoritmasının kullanım sebebinin de bu olduğu belirtilmektedir.

Çizelge 2.3. Çalışma [1]'de sınıflandırma amacıyla elde edilen polarimetrik parametreler

Niteliklerin Sırası	Nitelik Açıklamaları
1	Doğrusal depolarizasyon oranı
2	Diferansiyel Depolarizasyon oranı
3	Eş kutuplu korelasyon katsayısı
4	Çapraz polarize korelasyon katsayısı
5	Çapraz polarize korelasyon katsayısı
6	Entropi
7	Anizotropi
8	Polarimetrik Özvektör parametresi
9	Oryantasyon açısı tahmini


2.4. Pasif Radarlar ile Sınıflandırma

Yıllardır pasif radarlar geleneksel aktif radarlara göre elektronik karşı önlemlere karşı düşük hassasiyet, karşı-gizlilik avantajı ve elektromanyetik emisyon olmaması gibi avantajları nedeniyle bilim camiasının dikkatini çekmiştir [2]. Pasif radarlar özellikle askeri uygulamalar için ilgi çekici bir teknolojidir.

Pasif radarlar, işbirlikçi olmayan mevcut aydınlatıcılardan sinyal kaynakları olarak

yararlanır ve hedef için bir veya daha fazla alıcı kullanılır. Özellikle düşük maliyetli pasif radarlar ile gerçek zamanlı işleme artık mümkün olduğundan, bu tür sistemlere yönelik bilimsel ve savunma sektörünün ilgisi devam etmektedir. Pasif radarlar frekans tahsisi gerektirmez ve elektromanyetik dalga üretmezler. Bu durum, pasif radarların kullanımını deniz ve hava trafik gözetimi gibi sivil uygulamalar için de çekici hale getirmiştir.

Manno-Kovacs ve diğerleri (2019) çalışmalarında pasif ISAR ile otomatik hedef sınıflandırma yeteneklerini araştırmaktadırlar. Çalışmada önerilen yöntemde, radar görüntüleme ile üretilen hedeflerin menzil/çapraz menzil görüntüleri ile tamamen görüntü tabanlı bir hedef çıkarma ve sınıflandırma yaklaşımı baz alınmaktadır. Sunulan yöntem, gerçek pasif ISAR verileri üzerinde test edilmektedir. Şekil 2.3.'de menzil ve çapraz menzil parametreleri kullanılarak elde edilen 2 boyutlu görseller verilmektedir. Bu şekilde elde edilen görüntüler sınıflandırmada kullanılan giriş verileridir.




Şekil 2.3. Çalışma [2]'de verilen üç hedefe ait P-ISAR görüntüsü; a) kargo gemisi 200,63m uzunluk 26,5 m genişlik, b) kargo gemisi 184m uzunluk 27 m genişlik, c) GPS'e sahip gemi 32 m uzunluk 7m genişlik

Çalışmada öznitelik çıkarımı amacıyla görüntüler üzerinde çeşitli yöntemler uygulanmaktadır. Uygulanan yöntemler sonrasında elde edilen görüntüler şekil 2.4.'te verilmektedir.



Şekil 2.4. Örneklere uygulanan ön işleme ve öznelilik çıkarım aşamaları; girdi, filtreleme sonrası görüntü, doku filtrelemesi sonrası görüntü, yönelimli filtreleme sonrası görüntü, kaynaşmış (fused) nitelik görüntüsü, nihai filtreleme sonrası hedef görüntüsü, nihai hedefin uzunluk görüntüsü

12 farklı sınıfın sınıflandırıldığı çalışma [2]'de sınıflandırma yöntemi olarak geri alma tabanlı (retrieval based) bir yöntem öneriliyor. Çalışmada önerilen yöntemin başarısının gösterilmesi amacıyla SVM, karar ağacı ve k-NN tabanlı yöntemler de çalışma kapsamında test ediliyor. Şekil 2.5.'te önerilen yönteme ait karmaşıklık matrisi ve sınıflandırıcı modellere ait ARR değerleri verilmektedir. Değerler incelendiğinde önerilen yöntemin diğer yöntemlere göre daha başarılı olduğu söylenilmektedir.



Şekil 2.5. Çalışma [2]'de verilen sınıflandırma sonuçları; a) önerilen yönteme ait karmaşıklık matrisi, b) sınıflandırıcı yöntemlerin ARR yönünden karşılaştırılması

3. RADAR VERİSİ İLE HEDEF SINIFLANDIRMADA KULLANILAN MATERYAL VE YÖNTEMLER

Sınıflandırma, örüntü tanıma, kümeleme gibi birçok alanda yapay zekâ algoritmaları etkili yöntemlerdir. Briones ve diğerleri (2012) çalışmalarında hedefleri tespit edip yapay zekâ yaklaşımlarıyla nesneleri sınıflandırarak birbirinden ayırabilen bir radar tabanlı sistemden bahsetmektedirler. Bu sistemin sahip olduğu yapay zekanın eğitilmesi için gerekli olan veriler, radarın tespit modun elde edilen radar izlerinden oluşmaktadır. İnsan, hava aracı ve kamyonlardan yansıyan radar verileri, hedef nesnelerin sınıflandırılması için kullanılmaktadır. Simülasyondan elde edilen sonuçlara göre radar tabanlı sistemlerin farklı nesneleri tespit edip yapay zekâ modelleri vasıtasıyla sınıflandırılmasında başarılı olduğunu göstermektedir. Hedef nesnelerin sınıflandırılmasında yapay sinir ağlarının eğitilmesinde yüksek çözünürlüklü radar görüntüleri kullanılmaktadır [23].

Kouba ve Usaf (1992) çalışmalarında doppler imzasının elde edilmesi, veriye gürültü eklenmesi, veriden öznitelik çıkarımı, sinir ağının eğitilmesi ve hedef nesnelerin tanımlanmasının doğruluğunu belirlemek için gerekli olan test aşamaları tanımlamaktadırlar. Bu çalışma gerçekleştirilinceye kadar yapay siniri ağları kelime tahmini ve tanıma amacıyla kullanılırken, burada ilk kez radar hedeflerinin tanımlanması için kullanılmaktadır [24]. Bahsedilen bu yapay sinir ağına sağlanan öznitelikler, radar sinyalinde elde edilen özniteliklerdir.

Doppler radarının kullanıldığı ve insan hareketlerinin incelendiği bir çalışmada ise elde edilen sinyallere zaman ve sıklık analizleri yapılarak çıkarılan öznitelikler ile makine öğrenmesi algoritmaları eğitilerek sınıflandırıcının farklı tipteki hareketleri ayırmada başarılı olduğu ancak birbirine benzer el salınımlarının hareket yönünü kestirmede başarısız olduğu belirtilmektedir [25].

Düşük güçlü, kısa menzilli doppler darbe radar sisteminin kullanıldığı başka bir çalışmada da insan, köpek ve bunlar dışındaki nesneleri gürültü olarak etiketlendirerek sınıflandırma yapılması amaçlanmıştır. Zaman sıklık analiz teknikleri ile öznitelikler elde edilerek ve yapay sinir ağları, SVM ve karar ağacı algoritmaları ile deneyler yapılarak sınıflandırma performansları değerlendirilmektedir [26].

Gray ve Brastrom (2002) çalışmalarında hedef nesnelerin imha edilip edilmediğinin belirlenmesinde sensörlerden elde edilen verileri tahmin için kullanan bir yapay zekâ

algoritması kullanmışlardır. Chappell ve diğerleri (1992) çalışmalarında ise sinir ağlarını kullanarak sistemin durumu için kestirim işlemi gerçekleştirmektedirler. Gelecekte yapılacak çalışmalarda yapay zekanın karar mekanizması olarak kullanılması hedeflenmiştir.

3.1. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi algoritmaları denetimli öğrenme ve denetimsiz öğrenme olarak ikiye ayrılmaktadır. Denetimli öğrenme algoritmaları etiketlenmiş veri setine ihtiyaç duyarlar. Eğitim sonucunda öğrendiği bilgi ile algoritma, sonrasında test verisindeki örneklemelerin etiketini belirlemeye çalışır. Denetimli öğrenme yaklaşımında belirlenen bir uyarıcıya istenen sonucun ne olması gerektiği verilerek ağın eğitimini sağlamak için bir öğretici kullanılmaktadır [29].

Denetimli öğrenme yaklaşımlarında eğitim için bir veri setinin bulunduğu var sayılır. Sınıflandırıcı modeller, daha önceden mevcut bir bilgiden faydalanılarak oluşturulmaktadır. Denetimli öğrenme modellerine örnek olarak, regresyon analizi, karar ağacı, rastgele orman, k-en yakın komşu, sinir ağı modelleri ve destek vektörü makinesi verilebilir. Denetimli öğrenme kapsamına giren bir sorunun, önceden etiketlenmiş veri seti bulunmalıdır. Bir denetimli öğrenme modelinin öğrenebileceği bu örnekler sayesinde veri içerisindeki tekrarlara veya ilişkilere uyum sağlamak için veri içerisindeki bağlantılar kullanılmaktadır. Model başarılı bir şekilde eğitildiğinde, yeni veri girişleri sağlanırsa eğitilen model kendi tahminlerini yaparak öğrendiği bilgileri kullanabilmektedir [59]. Her eğitim örneklemini niteliklerden ve etiketten oluşmaktadır. Sınıflandırma probleminde de her eğitim örneklemini bir nitelik setinden meydana gelmektedir. Denetimli öğrenme sayesinde bu nitelikler sayesinde örneklemin etiketi tahmin edilmektedir.

Makine öğrenmesi algoritmaları; karar ağacı, rastgele orman ve destek vektör makinesi incelenecektir.

3.1.1. Karar ağacı

Karar ağacı algoritmasının görevi veri setini belirli kurallara göre eşit olarak alt gruplara bölmektir. Karar ağacı modelleri böl ve yönet yaklaşımını uygulayarak problemleri çözümleyen hiyerarşik bir yapıya sahiptir. Karar ağacı modelleri makine öğrenmesi modelleri içinde en basit metotlardan birisidir. Karar ağacı modelleri daimî veri seti olmayan sınıflandırmalar için daha etkili bir yöntemdir. Verinin niteliklerine göre belirlenen sınırları

referans olarak ikiye böler ve bölünmelerin toplamında oluşan ağaç yapısı sayesinde sınıflandırma yapmaktadır. Bu algoritma kök boğum, orta boğumlar ve yapraklardan meydana gelmektedir. Her boğumda karar vererek farklı bir dala veya yaprağa ulaşarak sınıflandırma işlemini gerçekleştirmektedir.

Her boğumda, dalları farklı sonuca sahip bir test fonksiyonu bulunmaktadır. Bir veri geldiğinde, her boğumda bu fonksiyon işletilir ve değere bağlı olarak dallardan biri tercih edilir. Bu işlem kökten itibaren yapraklara varıncaya değin uygulanmaktadır. Yapraktaki değer örneklemin tahmin edilen değeridir. Başlangıçta karmaşık olan bir problem basit ve art arda gerçekleştirilen adımlara bölünmektedir [30].

Sınıflandırmada sırasında bir yaprak, boğum, giriş noktasından bu bölgeye denk gelen örneklemelerin aynı değere sahip olan örneklemelere ait olduğunu göstermektedir. Kararın verilmesini sağlayan mekanizma ile belirten sınırlar kökten yaprak boğuma ulaşan yol üzerindeki mevcut boğumlarda uygulanan diskriminantlar aracılığıyla belirtilmektedir. Öğrenme sırasında veri setinin içerdiği bilinmezliğin karmaşıklığına göre ağaç zamanla değişiklik göstermektedir ve yeni dallar ile yapraklar eklenmektedir.


Karar ağaçları, veri setindeki örneklemelere göre öğrenme sırasında daha küçük parçalara bölen bir dizi soru ile gösterilmektedir. Bu parçalara göre hiyerarşik olarak oluşmuş bir ağaç meydana gelmektedir. Tüm boğumlar, seçilen bölmelere göre belirlenen özniteliklere göre kurallardan oluşmaktadır. Kökten yapraklara doğru ilerlerken dallarda özniteliklerin ayrışması amacıyla elde edilen değerler sunulmaktadır. Kuralların tümünün sonuçları dallarla gösterilmektedir. Yapraklar çözümün meydana geldiği aşamadır [31].

Karar ağacı algoritmalarının açısından en kritik karar her bir boğumda verilerin nasıl ayrılacağıнын belirlenmesidir. Sınıflar arası ayrımın en doğru olacak şekilde gerçekleştirilmesi için muhtelif ayrışma değerleri tespit edilmektedir. Bu ayrışma değerleri, ayrışmadan önceki ve sonraki sınıf dağılımına bağlı olarak belirlenmektedir. Bu ayrışma değerlerinden birisi gini ölçütüdür [32].

Algoritma, ayırma işlemi için, en doğru sonuca ulaştıracak özniteliği taramaktadır. Farklı karar ağaç yaklaşımları için ayırtaç fonksiyonu da ayrışmaktadır. Ayırma parametreleri için en önemli şart boğumdaki saflığı artırmaktır.

3.1.2. Rastgele orman

Rastgele orman algoritması, her biri rastgele bir öğrenme setinin alt kümesini veya verilen öz niteliklerinin rastgele bir alt kümesiyle eğitilen birden fazla karar ağacının eğitilerek çıktıların bir oy hakkı olacak şekilde oylama sonucunda çoğunluğa göre sınıflandırma yapmaktadır [33]. Karar ağaçlarının bir birleşimidir. Rastgele orman algoritmasının başarısı, ormandaki ağaçların sınıflandırma başarımına ve bu ağaçlar aralarındaki ilişkiye bağlıdır. Rastgele Orman algoritması Leo Breiman [33] tarafından Amit ve Geman'ın (1997), yazı karakteri teşhisi üzerine çok sayıda geometrik öz nitelik tanımladığı ve her bir boğumdaki en iyi ayrışma için bunların rastgele bir seçimini araştırdıkları önemli bir makaledeki deneysel çalışmalarından ilham alarak ortaya koymaktadırlar [33].



Şekil 3.1. Rastgele Orman Algoritması [34]

Rastgele orman içerisindeki karar ağaçlarının tahminleri toplanarak genel doğruluk performansı ciddi derecede artırılabilir. Karar ağaçlarına ayrı ayrı verilebilecek veri seti azalmış olduğu için öğrenme süresindeki azalma da bir diğer avantajdır [30]. Bu durum genellikle birden çok sınıflandırıcı ile sınıflandırma sırasında ve regresyon ağacı yapılarında ortaya çıkmaktadır. Tek bir karar ağacını ortaya koyacağı hata oranını düşürmek için kullanılmaktadır.

Rastgele orman algoritmasındaki her bir karar ağacı veri setindeki bir alt veri seti ile eğitilerek bir sınıflandırma işlemi yapmaktadır [57]. Sınıflandırma son aşama olarak tüm karar ağaçları arasında en çok oyu olan çıktı sınıflandırma işleminin sonucu olarak ortaya

çıkmaktadır. Bu sayede rastgele orman algoritması tüm evrende en iyi değere ulaşırken tek bir karar ağacı sınırlı evrendeki en iyi değerde kalabilmektedir [30].

3.1.3. Destek vektör makineleri


Destek vektör makineleri iki sınıftan oluşan veri setlerinde sıklıkla tercih edilen, bilhassa çekirdek fonksiyon vasıtasıyla yüksek boyuta sahip uzaya geçişin sağlanmasıyla doğrusal yapıda olmayan sınıfların ayrımı için tercih edilen oldukça başarılı bir metottur. SVM sınıflandırmada iki sınıfı birbirinden ayıran özellik, en uygun hiper düzlemin belirlenerek probleme çözüm olacak şekilde kullanılmasıdır [35].

Destek vektör makineleri genel olarak ikiye ayrılabilir. Probleme bağlı olarak doğrusal ve doğrusal yapıda olmayan çekirdek fonksiyonlar tercih edilebilir. Genel olarak değerlendirildiğinde SVM sınıflandırıcılar, sınıflara ait verileri, bir hiper düzlem belirleyerek sınıfların arasında en yüksek mesafeye göre ayrılmasını sağlayan bir sınıflandırma fonksiyonu keşfetmektedir. Çalışmadan bağımsız olarak makine öğrenme modellerinden ayrılmasını sağlayan temel fark, optimum ayırma düzleminin elde edilmesinde yer alan matematik tabanlı hesaplamalardır. En uygun hiper düzleme mesafe olarak yakın örneklemeler “destek vektörleri” olarak isimlendirilmektedirler [35].

Doğrusal olarak iki sınıfı birbirinden ayırmak istendiğinde $g(x) = w^T x + w^0$ denklemi doğrusal bir hiper düzlemi göstermektedir. İki sınıfı birbirinden ayıran bir düzlemde yeni bir noktanın nereye ait olduğu denklemde yerine konulduğunda $g(x) > 0$ ise bir sınıfa $g(x) < 0$ ise diğer sınıfa ait olduğu tahmin edilmiş olunur [30].

Destek vektör makineleri modellerinde destek vektör olarak seçilmiş örneklemeler karar sınırının belirlenmesinde etkili olmaktadır. Sınıfların ayrılmasını sağlayan destek vektörleri, aralarındaki mesafenin en fazla olmasını sağlayacak şekilde seçilmektedir [35].

Doğrusal olarak ayrılmayan sınıfların ayrımı için uygun yöntem, doğrusal olmayan bir sınıflandırıcı modeli kullanmak yerine, doğru şekilde belirlenmiş temel fonksiyonları tercih ederek ve bunun sayesinde çekirdek fonksiyonlar vasıtasıyla bir dönüşüm uygulayarak sorunu doğrusal bir probleme çevirerek yeni bir uzaya uygulamaktır. Çekirdek fonksiyonlar vasıtasıyla örneklemeleri yeni bir uzaya direkt taşımaktan daha kolay bir şekilde çözmektedir [30].



Şekil 3.2. Doğrusal Olarak Ayrılmış İki Sınıfın Grafıksel Gösterimi [30]

Parabolik bir çekirdek fonksiyonundan ziyade radyal tabanlı çekirdek fonksiyon tercih edildiğinde hem işlemci üzerindeki yük azalmış olacak hem de bir veri setini herhangi bir uzayda ayıracak hiper uzayın bulunup bulunmadığını daha hızlı bir şekilde neticelendirecektir [36]. Örneğin gauss çekirdeği radyal tabanlı çekirdek fonksiyonuna bir örnektir. Ayarlanabilir parametre sigma, çekirdeğin performansı için kritik öneme sahiptir ve problem göz önüne alınarak seçilmelidir. Aşırı tahmin gerçekleştiğinde, üstel ifade yaklaşık olarak doğrusallaşmaya başlamakta ve yüksek boyutlu izdüşümü doğrusal olmayan yapısını kaybetmeye başlamaktadır. Bir diğer yandan, eğer gerçek değerden daha düşük tahmin gerçekleşirse, fonksiyonu düzgünleşmekte ve hiper düzlem ise eğitim verisindeki gürültü örneklerine karşı son derece duyarlı hale gelmektedir [37].

Destek vektör makinelerinde çok sınıflı veri setleri ile sınıflandırma yapılmak istendiğinde her biri birbiriyle ikili sınıflandırmaya tabii tutulmaktadır. Bu yaklaşıma bire bir yöntemi denmektedir. Çoklu sınıflandırma problemi ikili sınıflandırma problemine dönüştürüldükten sonra bir oylama metodu ile karar verilmektedir [30].

Çok sınıflı sınıflandırma problemlerinde destek vektör makineleri ile uygulanan bir diğer yaklaşım ise bir sınıf haricindeki tüm sınıfların bir sınıf olarak ele alındığı yaklaşımdır. Bu yöntemde sınıf sayısı kadar destek vektör makinesi oluşturulmaktadır. Bir örneklemin sahip olduğu sınıf bilgisi karar fonksiyonuna verilerek en büyük değer hangi sınıfa sahip ise o sınıfa ait olmaktadır [38].

3.2. Sinir Ağları

Beyin nöronları referans alınarak geliştirilen sinir ağı modelleri, sınıflandırma ve regresyon işlemlerinde kullanılmaktadır. Temelde bir sinir ağı, girdi katmanı, gizli katmanlar, çıktı katmanı ve katmanlarda bulunan sinir hücrelerinden meydana gelmektedir. Katmanlardaki sinir hücrelerinin miktarı özniteliklere, sınıf miktarına ve belirlenen gizli katman miktarına göre belirlenmektedir. Farklı katmanlardaki sinir hücreleri birbirine bağlı durumdadır. Gizli katmanlardaki sinir hücrelerinin artırılması bazen öğrenme kapasitesinin artmasını sağlarken bazen de azalmasına sebep olmaktadır. Bu durum temelde problemin cinsine bağlıdır. Probleme bağlı olarak en uygun gizli katman ve sinir hücresi miktarı belirlenmelidir [39].

Sinir ağlarının kullanılma sebebi, öğrenme sistemini kurmak için bir dizi girdi verisi ve bu verilere ait çıktı verisi kullanarak sistemin yanıtları bulmasıdır [29]. Bu sistem yanıtlarının başarımının artırılması için ağırlıklar birçok tekrar ile değiştirilerek denenebilmektedir. Model sistemin çıktısı ile bilginin uzmanından gelen yanıt arasındaki hata farkı ölçülmektedir. Hata miktarı daha sonra modeli geliştirmek için kullanılmaktadır. Bu aşamada ağırlıklar sinir ağları için güncellenir ve böylece öğrenme modelinin çıktısı bilgi uzmanının yanıtına yakınsayarak giderek eşleşmektedir [29].

Geri yayılım algoritmaları ile her bir tekrar sonucunda güncellenen parametreler vasıtasıyla hata oranının giderek azaldığı bir eğitim amaçlanmaktadır [40]. Optimizasyon, sınıflandırma, örüntü tanıma, kümeleme gibi konularda sinir ağlarının ortaya koyduğu çözümler oldukça etkindir.


Sinir ağlarında her sinir hücresi kendisinden gerçekleştirmesi beklenen görevi başarmak ve istenen çıktıyı vermesi için tasarlanmaktadır. Sinir hücrelerinin içinde gerçekleşen ve çıktının belirlenen değerler arasında bir değer almasını sağlayan fonksiyonlara, aktivasyon fonksiyonları ismi verilmektedir. Hiperbolik tanjant, Gauss, lojistik sigmoid ve doğrusal aktivasyon en iyi bilinen aktivasyon fonksiyonlarıdır. Bu fonksiyonların girdisi üzerindeki etkisi her birine özgüdür ve modelden beklenen başarımlarına göre geliştirici tarafından dikkat edilerek belirlenmektedir. Sınıflandırma problemleri göz önüne alındığında doğrusal olmayan aktivasyon fonksiyonları doğrusal aktivasyon fonksiyonlarına göre daha iyi sonuçlar üretmektedirler [29].

3.2.1. Algılayıcı

Algılayıcılar tek katmanlı, basit yapay sinir ağı modelleridir. Temelde eğitilmesi mümkün tek bir yapay sinir hücresinden meydana gelmektedir. İlk olarak Cornell Havacılık Laboratuvarı'ndaki Amerikalı psikolog Frank Rosenblatt tarafından 1957'de ortaya atılmaktadır. Warren McCulloch ve Walter Pitts'in çalışmalarından (biyolojik sinir hücresi ve öğrenebilme yeteneği) ilham alan Rosenblatt, bir sinir hücresi gibi davranış sergileyen bir makine geliştirmeyi amaçlamaktadır [41].

Algılayıcı, temelde denetimli bir öğrenme modelidir. Ağın eğitimi etiketli veri seti ile gerçekleştirilmektedir. Algılayıcının öğrenme yaklaşımı hataya dayandırılmış bir öğrenme yaklaşımıdır [41]. Algılayıcı sistemdeki hataları zamanla öğrenerek, hataların en aza indirgenmesi amaçlanmaktadır.

Bir algılayıcı yapısında girdi, eşik değer, ağırlıklar, ağırlıklı değer hesaplama fonksiyonu, aktivasyon fonksiyonu ve çıkış değeri bölümlerinden oluşmaktadır. Her giriş değerinin kendi ait ağırlığı ile çarpılmakta ve bu çarpılan değerler toplanmaktadır. Bu işlem toplama fonksiyonunda gerçekleştirilmektedir. Toplama fonksiyonundan elde edilen değer aktivasyon fonksiyonunun girdisidir ve aktivasyon fonksiyonundaki işlem sonucunda elde edilen değer çıkış değeridir.



Şekil 3.3. Temel bir algılayıcının yapısı

3.2.2. Çok katmanlı algılayıcı

Doğrusal olarak ayrılarak çözülebilen sınıflandırma problemlerinde tek katmanlı algılayıcılar yeterlidir. Ancak çoğunlukla gerçek hayattaki problemler doğrusal olarak ayrılabilir problemler değildir. Bu sebeple tek katmanlı algılayıcılar çoğu zaman yetersizdir. Doğrusal olarak ayıramayan sorunların çözümü amacıyla tek katmanlı ve basit algılayıcılara

bir ağırlık katmanı dahil edilerek sorunun çözümü hedeflenmektedir. Bu yaklaşım aslında çok katmanlı algılayıcıların temelidir. Yeni ağırlık katmanının eklenmesiyle doğrusal ikinci bir ayraç daha oluşturulmaktadır [42]. Bir doğrusal ayırıcı ile ayrılamayan problemler bunun gibi birden çok doğrusal ayırıcı ile çözülmeye çalışılmaktadır.

Doğrusal olmayan problemlerin çözülmesi için ortaya konan çok katmanlı algılayıcılarda ortaya eklenen ağırlık katmanlarında yapılan işlemlerin ne olduğu problemin çözümü ve performansın artırılması için önemlidir. Basit problemler için geliştirilen yapılarda orta katmanlarda beklenen çıktılar tahmin etmek kolayken, karmaşıklığı yüksek problemler için bunu belirlemek daha zordur [58].

Çok katmanlı algılayıcılarla doğrusal olmayan, karmaşık problemlerin çözümünde orta katmanların ağırlıklarını tespit etmek için standart optimizasyon yöntemlerinden yararlanılmaktadır. Tüm sinir ağının çıktısı üzerinden, yine çıktı cinsinden ifade edilen bir hata fonksiyonu belirtilmektedir. Gradyan tabanlı indirgeme yöntemleri kullanılarak sürekli ve türevlenebilir hata fonksiyonu oluşturulmaktadır. Bu fonksiyondan yararlanarak ara katmanlardaki ağırlıkların belirlenmesi sağlanmaktadır [42].

3.2.3. Derin öğrenme modelleri

Derin öğrenme modelleri çok katmanlı yapay sinir ağlarından meydana gelmektedir. Girdi katmanı, gizli katmanlar, çıktı katmanından oluşmaktadır. Çok sayıdaki gizli katman vasıtasıyla büyük miktarda nitelik ele alınarak öğrenme yapılmaktadır. Aşırı öğrenme ihtimalini azaltmak için katmanlar arasındaki bağ miktarı azaltılabilmektedir.


Williams ve Zipser yinelenen sinir ağları algoritmalarını geliştirmişlerdir. Kouba ve Usaf (1992) çalışmalarında ilk kez radar hedeflerini tanımlamak için sinir ağlarını kullanılmaktadırlar. Bir girdi vektörü ve bir ağırlık matrisinin çarpılması ile bir sonuç vektörü elde edilmektedir. Ağırlık matrisi, gradyan inişe ve etiketlenmiş girdi vektörlerine göre değiştirilmektedir. Böylece olması istenen sonuç ile elde edilen sonuç arasındaki hata miktarı en aza indirilmektedir. Hem gizli katmanlardaki düğümler hem de çıktı katmanlarındaki düğümler sonuç vektöründe bulunmaktadır. Yinelenen sinir ağlarının en büyük dezavantajlarından birisi karmaşık öğrenme işlemleridir [24]. Yinelenen sinir ağları sadece sıralı bir veri dizisine uygulanabilmektedir. Her bir devirde istenilen ve ulaşılan çıktılar arasındaki hatalar giderek artan bir şekilde ele alınmaktadır. Gerçek zamanlı olarak yinelenen öğrenme modeli, gradyan indirgeme vasıtasıyla, istenen ve elde edilen çıktı

düğüm değerlerinin arasındaki ortalama hatanın karesinin minimuma indirilmesi hedeflenmektedir.

Geleneksel sinir ağı modelleri, yeni gelen örneklerle önceki örnekler arasında bir ilişki olabileceğini hesaba katmazlar. Ancak yinelenen sinir ağları bu ihtimali göz önüne almak üzere çıkartılmış, elde edilen bilginin kalıcı olmasına yarayan döngüleri olan sinir ağı yapılarıdır. Ara katmandaki bir çıktı değeri, bir başka sinir hücresinin girdisi olabilme ihtimalinden dolayı son çıktı değerinin hata oranları her noktada bir miktar daha azalmış olmaktadır.

Görüntü verilerini işlemek için CNN, MLP temel alınarak geliştirilmiş özel modellerdir. Görüntü verileri, genel istatistiksel verilerden farklıdır; örneğin, bir görüntüdeki bir piksel genellikle çevresindeki piksellere ve hatta uzaktaki piksellere göre alakalıdır [49]. Bu nedenle, CNN'ler MLP'lerdeki ağırlıkların şeklini değiştirir ve İki farklı katman arasındaki tam bağlantılardaki ağırlıklar evrişimli çekirdeklerle değiştirilmektedir [50]. Evrişimli çekirdeklerin görünümü, CNN'lerin eğitim sürecinde görüntü verilerinin yerel bilgilerinin dikkate alınmasını mümkün kılmaktadır. CNN'ler, MLP'ler için imkânsız olan sürekli evrişimli çekirdekleri hareket ettirerek görüntü verilerinin dağıtımını öğrenmektedir. Özel yapı ve eğitim yöntemleri, beynin gördüklerimizi nasıl işlediğiyle daha tutarlıdır. Sonuç olarak, CNN'ler bilgisayarla görme alanında yaygın olarak kullanılmaktadır. Dikkat çekici bir şekilde, son çalışmalarda [51], [52], [56], CNN'lerin zaman dizisi verisini işlemeyi yinelenen sinir ağlarından bile daha iyi ele alabildiğini göstermektedir. Şekil 3.4'te klasik bir CNN modelinin gösterilmektedir. Ağ içerisinde evrişimli katmanlar, havuzlama katmanları ve tamamen bağlı katmanlardan oluşmaktadır.

Evrişimli bir katmanın işlevi, giriş resimlerinin genel ve yerel uzamsal bilgilerini tam olarak kullanabilen evrişimli çekirdekler (yani filtreler) tarafından sağlanır. Evrişimsel çekirdeklerdeki ağırlıklar ve sapmalar, öğrenilmesi gereken hiper parametrelerdir.



Şekil 3.4. Klasik bir CNN modelinin yapısı

Havuzlama katmanı genellikle evrişimli bir katmanı takip eder, ancak genellikle gerekli değildir. Havuzlama katmanının amacı, özellikleri değiştirmeden tutma öncülü altında fazla uydurmayı önlemek için verilerin boyutunu azaltmaktır. En yaygın havuzlama işlemi türleri, maksimum havuzlama ve ortalama havuzlamadır. Maksimum havuzlama işlemi, bir evrişimli katmanın çıkış matrisinin yerel bölgesindeki maksimum değeri seçmek için gerçekleştirilir. Benzer şekilde, ortalama havuzlama işlemi ortalama değeri hesaplamaktadır [49].

3.2.4. Öznitelik çıkarımı

Öznitelik çıkarım yöntemleri sınıflandırma sırasında karmaşıklığın azaltılması için kullanılmaktadır. Ham veriye öznitelik çıkarım yöntemlerinin uygulanmasıyla elde edilebilecek performansın daha az nitelik ile elde edilmesi hedeflenmektedir.

Öznitelik seçimi, sinir ağının başarısı için oldukça önemlidir. Öznitelik sayısının az ve örneklem sayısının nispeten çok olduğu durumlar sinir ağı modelinin eğitilmesinde katkı sağlamaktadır. Diğer yandan nitelik sayısı fazla olduğunda ve örneklem sayısı düşük olduğunda model sınıflandırmayı sağlayacak genellemeleri belirleyemeyeceğinden düşük performansa sebep olabilir [29].

Özniteliklerin veya veri setindeki boyutluluğun artması ile işlenmesi ve ele alınması gereken veri miktarı artmış olur. Yüksek miktarda öznitelik ile eğitimin gerçekleştirilmesi tercih edilebilir gibi görünse de daha az miktarda özneliğe sahip veri seti ile eğitilen bir sinir ağına göre daha düşük performans sergileyebilmektedir. Öznitelik sayısı arttıkça sinir ağlarının ezber yapmasını önlemek için örneklem sayısının ve çeşitliliğinin de buna bağlı olarak artması gerekmektedir. Bu duruma genel olarak boyutluluğun laneti ismi verilmektedir [29].

Sinir ağına daha önce verilmemiş her ek girdi, model tarafında yeni bir boyut kazandırır. Eğitim esnasında, girdi uzayının çıktı uzayına doğru bir şekilde eşleşmesi ve sinir ağının eğitilmesi için girdi uzayındaki her bir parçanın veri temsilcisinin bulunması gereklidir. Bu eşleşmenin gerçekleşmesi için de yeterli miktarda ve çeşitlilikte örneklem bulunmalıdır. Bu sebeple daha düşük boyutlu bir uzayı temsil edebilecek miktarda veriden çok daha fazla veriye ihtiyaç vardır [29].

Veri setindeki öznitelik sayısının artması, bellek, zaman ve örneklem dâhil olmak üzere eldeki kaynakları tüketmektedir. Bu durumla başa çıkmak için uygun, faydalı ve işe yarar niteliklerin seçilmesi içi yöntemler uygulanmaktadır. Öne çıkan özelliklerin bilinmesi ile

sinir ağını tasarlayan kişinin faydası olmayan veya az olan özellikleri kaldırarak veri boyutunun azaltılması sağlanabilmektedir [29].

Veri seti, örneklemelerin nitelikleri ve etiket arasında ilişki kurmasına yaramayacak nitelikler içerebilmektedir. Nitelik vektörleri, birbiri ile ilişkili, fayda sağlamayacak bilgileri içeren nitelikler barındırabilmektedir. Bu gibi durumlarda gereksiz olarak nitelendirilebilecek nitelikler çıkarılarak boyut azaltılmaktadır. Bu işlem nitelik seçimi, öz nitelik çıkarma veya ikisinin birleşimini içeren bir yöntem yoluyla yapılmaktadır [29].

Öz nitelik çıkarımı ve seçimi yöntemleri doğru uygulandığında öz nitelik sayısını azaltırken eğitim için gereken bilgiler korunmuş olur. Öte yandan, nitelik azaltma yöntemlerini fazlaca kullanmak düşük performansa sebep olabilmektedir. Bazı durumlarda öz nitelik azaltma sürecinde özel alan bilgisine de başvurulabilmektedir [29].

Sınıflandırma öncesinde karmaşıklığı azaltmak için öz nitelik çıkarım yöntemleri kullanılmaktadır. Gürültü kaldırma, FFT, STFT gibi sinyal verilerine uygulanan yöntemlerle öz nitelik çıkarımı gerçekleştirilmektedir. Öz nitelik çıkarımı sonrası elde edilen veriler makine öğrenmesi ve derin öğrenme modellerine girdi olarak verilmektedir [43].

3.2.5. Veri normalizasyonu

Bir sinir ağına veya herhangi bir makine öğrenmesi algoritmasına verilecek öz niteliklerin aynı değer aralığına olması için normalizasyon yöntemleri uygulanmaktadır. Böylelikle bir öz niteliğin değerlerinin niceliksel olarak büyük olmasının önüne geçilerek o niteliğin ağır basması önlenmiş olunur. Özellikle değer aralığı yüksek olan niteliklerin normalize edilmesi performansı oldukça artırmaktadır.

Normalizasyonda en çok tercih edilen değer aralıkları genelde (0 1) veya (-1 1) şeklinde olmaktadır.

3.2.6. Sınıf yönünden veri seti dengeleme yöntemleri

Denetimli öğrenme yöntemleri için veri setindeki örneklemelerin etiketlenmiş olması gerekmektedir. Bu işlem, bir sistem veya uzman tarafından her bir örneklemin ait olduğu grubunu gösteren değer atanmasıyla sağlanır. Atanan değer sayısal bir değer değil ise bilgisayarın algılayabilmesi için sayısal bir değere dönüştürülmelidir. Örneğin bir ikili sınıflandırma probleminde etiketler kadın ve erkek ise, bunların 0 ve 1 olarak eşleştirilmesi gerekmektedir.

Etiketleme işleminin ardından bir sınıfa ait örneklem sayısı diğer sınıfların örneklem sayısından fazla olduğu durumlarda veri setinde sınıf dengesizliğine sebep olmaktadır. Gerçek dünya verilerinde sıkça karşılaşılan bu tür durumlarda algoritma, azınlık durumundaki sınıfların karakteristik özelliklerini anlamada zorluk çekeceğinden bu sınıfları ayırt etmede sorun yaşamaktadır.

Genel olarak ele alındığında dengesiz veri seti sorunu, bir sınıf azınlık durumundayken o sınıfa ait kavramların yeterince temsil edilemediğinde ortaya çıkmaktadır. Bu durumda diğer sınıflara ait örneklem, bu sınıfa ait örneklemlerden daha ağır basmaya sebep olmaktadır [44].

Dengesiz veri setleri ile eğitilen makine öğrenmesi modellerinin ortaya koyduğu sınıflandırıcılar veri setinin büyüklüğünden bağımsız olarak yetersiz hale gelmektedir. Örneklemelerin çoğunun belli bir sınıfa üye olması, sınıflandırıcının da bu sınıfa göre sınıflandırma eğilimine girmesine sebep olmaktadır. Bu durumda veri seti ne kadar büyük olsa da sınıflandırıcının başarımının sorgulanmasına ve sınıflandırıcı modelin başarısız olmasına sebep olmaktadır [44].

Veri setindeki sınıf dengesini sağlamak için azınlık sınıflara ait örneklemelerin çoğaltılması veya çoğunluk durumundaki sınıflara ait örneklemelerin azaltılması gerekmektedir.

Çoğunluk durumundaki sınıfa karşı ön yargı oluşması sorunun çözümü için “çoğunluk sınıfına karşı eksik örnekleme tekniği”, “azınlık sınıfı üzerinden aşırı örnekleme tekniği”, “maliyete duyarlı öğrenme teknikleri” ve “öznitelik seçme/eleme” gibi yaklaşımlar ortaya atılmaktadır [44].

3.2.7. SMOTE sentetik azınlık aşırı örnekleme tekniği


Aşırı örnekleme yöntemlerinden birisi SMOTE tekniğidir. Temelde bu yaklaşımdaki mantık, azınlık sınıfa ait birkaç örnekleme enterpolasyon yapılarak yeni azınlık sınıfına ait örneklem oluşturulmasıdır. Böylece, çoğunluk sınıfa yönelik aşırı uyum problemi önlenerek azınlık sınıfı için belirlenen karar sınırlarının çoğunluk sınıfın sınırlarına yayılmasını desteklemektedir [45].

Bu yaklaşım sonucunda, azınlık sınıfın örneklemeleri aşırı örneklemlenerek öğrenen sınıflandırıcı üzerinde bu örneklemelerin daha etkin ve yönlendirici olması hedeflenmektedir. Böylece veri setindeki çoğunluk sınıfı işaret eden önyargıların oluşması engellenmiş

mümkün kılınmış olunur [46]. Fakat bu yaklaşımın kendine has bazı dezavantajları da bulunmaktadır. Bunlardan birisi, doğrusal bir dağılım bulunmamasından dolayı iki azınlık sınıf arasında bulunan, diğer sınıfların örneklemelerinin azınlık sınıfına ait örneklemlemiş gibi sınıflandırılmasıdır. Bu yöntem ile model performansının belirli zayıflıklara sahip olduğunu belirterek test ve doğrulama esnasında bu zayıflık kullanılan veri setine bağlı olarak karşılaşılabilmektedir. Bu zayıflığın etkisini azaltmak için, eğitim setlerinde SMOTE algoritmalarını uygulamadan önce örneklemelerin daha doğrusal bir şekilde ayrılması ile sağlanabilmektedir [46].

Rastgele aşırı örnekleme, azınlık sınıfına ait örneklemelerin rastgele kopyalanmasıyla sınıfların dağılımını dengelemeyi amaçlayan, buluşsal olmayan bir yöntemdir. Orijinal örneklemelerin kopyalanması sebebiyle aşırı uyum olasılığının artabilmesi durumu söz konusu olabilmektedir [44].

Rastgele Alt örnekleme durumunda ise çoğunluk sınıfına ait örneklemelerin rastgele bir şekilde seçilerek kaldırılması yoluyla veri setindeki sınıf dağılımını dengelemeyi hedefleyen sezgisel olmayan bir yaklaşımdır. Rastgele eksik örneklemenin en büyük problemi, bu yaklaşımın tümevarım sürecinde önemli sayılabilecek potansiyel olarak faydalı örneklemeleri dışlayabilmesidir [44].



Şekil 3.5. Rastgele alt örnekleme ve rastgele aşırı örnekleme algoritmalarının veri setini dengeli hale getirmesi [40]

3.2.8. Sınıflandırma performansının ölçülmesi

Eğitim doğrulama test verisi

İstatistik terminolojisine göre eğitim veri seti, modellerin eğitiminde kullanılan verilerdir. Doğrulama veri seti ise, modelin seçilmesi ve elde edilen tahminin hatasını tahmin etmek

için kullanılmaktadır. Öte yandan test seti, karar verilen modelin genel olarak hatasını belirlemek için kullanılır [35].

Makine öğrenmesi alanında ele alınan temel problemlerden birisi sınıflandırmadır. Sınıflandırma sırasında mevcut veri seti öğrenme ve test seti olarak ikiye ayrılır. Öğrenme seti, sınıflandırma için gerekli olan kuralların oluşması için modelin eğitimi için kullanılan veri setidir. Test seti ise eğitim sonucunda sınıflandırıcı modelin performansını tespit etmek için kullanılmaktadır. Böylelikle sınıflandırıcılar öğrenme veri setinden bağımsız bir test veri seti ile değerlendirilmiş ve böylelikle genelleme hatası minimuma indirgenmiş olur.

En uygun sınıflandırıcı ayarlamasını bulmak için ideal yaklaşım, örneklemelerden üç bağımsız veri setini rastgele üretmektir: bir eğitim veri seti, bir doğrulama veri seti ve bir test veri seti [29].

Eğitim veri seti, istenilen sonuçları elde etmek için sinir ağındaki ağırlıkların belirlemek veya eğitmek için kullanılan bir dizi örneklemidir. Doğrulama seti, en iyi sınıflandırıcı ayarlamasını ve eğitim değerlerini belirlemek için kullanılan bir örneklem setidir. Örneğin, eğitim tekrarlarında veya optimum devir miktarını öğrenmek için eğitim esnasında sinir ağının hata oranını takip etmek için başvurulmaktadır. En uygun gizli katman sayısını öğrenmek için ve birden fazla eğitilmiş sinir ağı arasından seçim yapmak için kullanılmaktadır. Doğrulama seti, eğitimi kontrol ederek gerekirse durdurmak için kullanıldığında sinir ağı, verileri çoktan dahil ettiği için iyimser bakış açısına sahip olarak önyargılıdır [29].

Test seti, sadece tamamen eğitilmiş olan modeli değerlendirmek için kullanılan bir veri setidir. Genelde bağımsız olması açısından eğitim ve doğrulama setlerinden ayrı olarak oluşturulur [29].

Eğitimin gerektiğinde durdurulması için ve en uygun noktayı belirlemek için doğrulama seti hatası da sıklıkla izlenmektedir. Genelde doğrulama setindeki hata oranı da eğitimin ilk aşamalarında azalma eğilimindedir. Öte yandan, sinir ağı veriyi gereğinden fazla öğrenmeye başladığında, doğrulama seti tarafından üretilen hata oranı artış göstermeye başlamaktadır [29].

Doğrulama hatasının azaldıktan sonra tekrar artmaya başladığı nokta optimum öğrenme anını işaret etmektedir. Bu noktada eğitim durdurulur ve en az doğrulama hatasının üretildiği ağırlıklar ile sinir ağında işlem için kullanılmaktadır [29]. Bu yaklaşım ile test verisi ile de

en iyi genelleme hata değerleri elde edilir. Bu noktadan sonra eğitimin devam etmesi halinde ağırlıkların değişmesi sonucunda eğitim setindeki örneklemelerin kendine özgü özellikleri ağır basmaya başlar test verisi sonucu elde edilen genelleme hatalarında artış görülmeye başlanır [29].

K-Kat çapraz doğrulama

Sınıflandırıcı modelin parametreleri optimize edilerek, en yüksek doğruluk ve en düşük hata oranı ile performansının yükseltilmesi amaçlanmaktadır. Bu sağlayan yöntemlerden bazıları ızgara arama, rastgele arama, çapraz doğrulama yöntemleridir. Bu yaklaşımlardan birisi veya birkaçı ile testler yapılarak en iyi performans parametrelerinin bulunması sağlanabilmektedir.

Çapraz doğrulama yöntemindeki temel yaklaşım, veri seti üzerinde yapılan işlemlerin doğruluğunun çapraz bir şekilde ölçülmesini sağlamaktadır. Burada veri seti k adet parçaya bölünmekte, sırasıyla her bir parça test verisi olarak belirlendikten sonra diğer parçalar öğrenme verisi olarak kullanılmaktadır. Bu işlem tekrarlanarak her bir parça için uygulanmaktadır. Böylece her bir parça hem test verisi hem de eğitim verisi olarak kullanılmış olduğu için tüm veri setini kapsayacak şekilde model doğrulanmış olmaktadır.

Karmaşıklık matrisi

Karmaşıklık matrisi, eğitilen model üzerinde test verisi ile tahmin gerçekleştirildiğinde test verisindeki örneklemelerin doğru tahmin edilip edilmediğini gösteren bir tablodur. Modelin tahmin başarımını gösteren performans ölçütleri için temel niteliğindedir [48].

Çizelge 3.1. İki sınıflı karmaşıklık matrisi

Gerçek Sınıf	Tahmin Edilen Sınıf	
	Gerçek Pozitif	Yanlış Negatif
	Yanlış Pozitif	Gerçek Negatif

Gerçek pozitif (GP): Doğru tahmin edilen pozitif örneklemelerdir. Gerçekte pozitif olan bir örneklemin tahmin edilen değerinin de pozitif yani aynı olduğunu gösterir.

Gerçek negatif (GN): Doğru tahmin edilen negatif örneklemelerdir. Gerçekte negatif olan bir örneklemin tahmin edilen değerinin de negatif yani aynı olduğunu gösterir.

Yanlış Pozitif (YP): Yanlış tahmin edilen negatif örneklemelerdir. Gerçekte negatif olan bir örneklemin tahmin edilen değerinin pozitif olduğunu gösterir.

Yanlış Negatif (YN): Yanlış tahmin edilen pozitif örneklerdir. Gerçekte pozitif olan bir örneğin tahmin edilen değerinin negatif olduğunu gösterir.

Doğruluk, bir model tahminleme yaptıktan sonra hangi oranda doğru tahmin yaptığını belirtir. Aşağıdaki formül ile hesaplanır.

$$Doğruluk = \frac{GP + GN}{GP + GN + YP + YN} \quad (3.1)$$

Kesinlik, bir modelin örnekleri pozitif olarak sınıflandırırken ne kadar başarılı olduğunu gösteren bir parametredir. Yanlış pozitiflerin artışı, gerçek pozitifleri ayırt etmede modelin başarısızlığını göstermektedir. Yüksek kesinlik değeri modelin başarımının yüksek olduğunu gösterir. Aşağıdaki formül ile hesaplanır.

$$Kesinlik = \frac{GP}{GP + YP} \quad (3.2)$$

Duyarlılık, pozitif örneklerin ne kadarının pozitif olarak tahmin edildiğini gösteren parametredir. Yüksek duyarlılık daha iyi model performansı anlamına gelmektedir. Aşağıdaki formül ile hesaplanır.

$$Duyarlılık = \frac{GP}{GP + YN} \quad (3.3)$$

F1 ölçütü, kesinlik ve duyarlılığın harmonik ortalamasının alınması ile edilir. Bu sayede tek bir parametre ile model başarımını değerlendirilmiş olur. Kesinlik K, duyarlılık D olmak üzere, aşağıdaki formül ile hesaplanır.


$$F1 = 2 \frac{K * D}{K + D} \quad (3.4)$$

4. DENEYSEL ÇALIŞMA VE ELDE EDİLEN SONUÇLAR

Doppler radar verisi kullanılarak nesne sınıflandırma yapılan birçok çalışma mevcuttur. Bu çalışma kapsamında konu hakkında güncel çalışmaların değerlendirilmesi sonucunda doppler radarından elde edilmiş veri seti ile özgün bir sınıflandırıcı model geliştirilmesi amaçlanmıştır. Bu kapsamda çalışma [15]'de kullanılan ve halka açık bir şekilde erişilebilen veri seti ile deneysel çalışmalar yapılmaktadır.

Veri seti üç sınıfa (İHA, insan, otomobil) ait doppler verisi içermektedir [15]. Şekil 4.1'de veri setinde bulunan sınıflara ait örnekler verilmektedir. Veri seti ham radar verisinin işlenerek, 11x61 piksellerden oluşan iki boyutlu spektrogramlardan oluşmaktadır. Veri Seti içerisinde spektrogramlar csv dosyası olarak tutulmaktadır. Örneklemeler doppler hücresi başına farklı mesafe aralıklarındaki sinyal gücünü içeren iki boyutlu grafiklerden oluşmaktadır. Veri Setinde 17485 adet örneklem bulunmaktadır.

Her sınıf görsel olarak farklı karakteristiğe sahiptir. İlk olarak İHA'lar düşük RCS'ye sahiptir bu yüzden sinyal gücü düşüktür. Ayrıca küçük ve kompakt olmaları sebebiyle sinyal gücü az sayıda hücre tarafından algılanmaktadır. İkinci olarak arabalar, büyük ve metal olmaları sonucunda büyük RCS'ye sahiptir. Farklı hızlarda, hareketli parçalarının olmaması sebebiyle ortalama sinyal gücü birkaç doppler hücresi tarafından algılanmaktadır. Son olarak insan sınıfındaki örneklerde, ortalama sinyal gücünde ve mesafe bazında daha az yayılmış yansımaya sahiptirler. Hareket halindeki kol ve bacaklar bulunması doppler hücrelerinde çeşitli geniş aralıkta sinyal değerleri elde edilmektedir [9]. Sınıflar arasındaki bu karakteristik farklılıklar sınıflandırıcı modellerin eğitilmesinde önemli yer almaktadır.



Şekil 4.1. Örnek doppler verileri; a) araba, b) İHA, c) insanlar

Veri Setindeki örneklerin dağılımı %32,71 otomobil, %28,97 İHA ve %38,32 insanlara aittir [15]. Çalışmada veri dağılımının dengeli olduğu ve sinir ağlarının eğitimi için uygun olduğu belirtilmektedir. Ancak veri seti oransal olarak incelendiğinde modelin ön yargılı bir şekilde

eğitilmesine sebep olabilecek oranda dengesizlik olduğu görülebilmektedir. Eğitim aşamasında veri setinin dengeli olması eğitimin kalitesini artıran bir etmendir. Veri setindeki örneklemelerin sınıflara göre dağılımı dengesiz olduğu durumlarda modelin tahmininde eğilimlere sebep olarak başarımın düşmesine sebebiyet verebilmektedir. Dengeleme amacıyla örneklemelerin azaltılması veya artırılması için çeşitli algoritmalar mevcuttur. Bu sebeple eğitim öncesinde ve sırasında veri setini dengeli bir şekilde ele alabilmek için çeşitli yöntemler kullanılmaktadır.

Deneysel çalışma ortamı olarak, veri setinin halka açık olarak sunulduğu kaggle platformu kullanılmaktadır. Platform üzerinde Python programlama dilinde kodlama ve çalıştırma imkânı bulunmaktadır. Elde edilen çıktılar sürümler halinde kaydedilerek istendiği takdirde eski haline geri dönülebilmektedir. Deneysel çalışmalarda hızlandırıcı olarak GPU T4 x 2 donanımı aktif edilmektedir.


4.1. Makine Öğrenmesi Tabanlı Modeller

Eğitimler esnasında en yüksek başarımın belirlenmesi için parametreler değiştirilerek eğitimler tekrarlanmaktadır. Bu amaçla rastgele orman algoritması ile gerçekleştirilen eğitimlerde orman içerisindeki ağaç sayısı parametresi değiştirilmektedir. Veri setinin dengeli olarak ele alınması algoritmada sınıfların dengelenmesini sağlayan parametre bulunmaktadır. Bu sayede rastgele orman algoritmalarının eğitilmesi için kullanılan veri setlerinde dengeleme işlemi için bir veri ön işlemi adımı uygulanmasına gerek yoktur. Veri setinin %80'i eğitim amacıyla kullanılırken %20'si ise test seti olarak ayrılmıştır.

4.1.1. Rastgele orman

Şekil 4.2'de orijinal veri seti ve dengeleme parametresinin aktif olarak eğitilen veri setinin doğruluk oranının ağaç sayısına göre değişim grafiği verilmektedir. Grafik incelendiğinde ağaç sayısındaki artış ile doğruluk değerinin arttığı görülmektedir. Veri setinin dengeli hale getirilmesinin rastgele orman algoritması ve bu veri seti özelinde fazla bir etkisinin olmadığı görülmektedir. Elde edilen doğruluk değerleri çizelge 4.1'de verilmektedir.


Geliştirilen rastgele orman algoritmasının, test verisi ile üzerinden tahmin ettiği değerler üzerinden şekil 4.3'teki karmaşıklık matrisi elde edilmiştir. Matris incelendiğinde hem doğru hem de yanlış tahminlerin eşit olarak dağıldığı ve modelin ön yargıya sahip olmadığı sonucu çıkarılabilmektedir.



Şekil 4.2. Rastgele orman algoritmasında doğruluk oranının ağaç sayısına göre değişim grafiği

Çizelge 4.1. Rastgele orman algoritmasında ağaç sayısına bağlı olarak doğruluk oranındaki değişim çizelgesi

	Ağaç Sayısı					
	5	10	20	50	100	500
Orijinal Veri Seti	0.8964	0.9139	0.9213	0.9327	0.9276	0.9336
Dengeli Veri Seti	0.8967	0.9173	0.9250	0.9319	0.9345	0.9365



Şekil 4.3. Rastgele orman algoritmasının gerçekleştirdiği tahminler üzerinden elde edilen karmaşıklık matrisi


Çizelge 4.2’de rastgele orman algoritmasının eğitilmesi sonrasında test verisi ile gerçekleştirilen tahminlerden elde edilen karmaşıklık matrisinden elde edilen performans değerleri verilmektedir.

Çizelge 4.2. Rastgele orman algoritmasının tahmini sonucu elde edilen performans değerleri

Doğruluk	Kesinlik	Duyarlılık	F1 Ölçütü
0.931	0.928	0.929	0.928


4.1.2. Destek vektör makinesi

Literatürde radar verisi ile hedef sınıflandırma amacıyla birçok çalışmada tercih edilen SVM algoritması ile deneysel çalışmalar gerçekleştirilmektedir. Eğitim öncesinde veri setinin dengeli hale getirilmesi için SMOTE algoritması ile aşırı örnekleme yapılmaktadır. İki den çok sınıftan oluşan veri setlerinin dengeli hale getirilmesinde kendini birçok çalışmada kanıtlamış olan SMOTE algoritması tercih edilmektedir [53-55]. Şekil 4.4'te orijinal veri seti ve SMOTE algoritması sonucu örneklem sayısının eşitlendiği gösterilmektedir.




Şekil 4.4. Orijinal veri setinin dağılımı ve SMOTE algoritması ile dengeleme yapıldıktan sonraki dağılım

Veri setinin dengeli hale getirilmesi ile modelin ön yargılı davranmasının önüne geçilmiş olmaktadır. Orijinal veri seti ve dengelenmiş veri seti ile gerçekleştirilen eğitimler sonucunda elde edilen karmaşıklık matrisleri şekil 4.5 ve 4.6'da verilmektedir.




Şekil 4.5. Orijinal veri seti ile SVM algoritmasının tahmini ile elde edilen karmaşıklık matrisi




Şekil 4.6. SMOTE algoritması ile dengeli hale getirilmiş veri seti ile SVM algoritmasının tahmini ile elde edilen karmaşıklık matrisi

Eğit ve test et yaklaşımının yanında k-kat çapraz doğrulma yaklaşımı ile de SVM algoritması eğitilmektedir. Bu yaklaşım sonucunda elde edilen karmaşıklık matrisleri şekil 4.7 ve 4.8’de verilmektedir.



Şekil 4.7. Orijinal veri set ve k-kat çapraz doğrulama yaklaşımı ile eğitilen SVM algoritmasına ait karmaşıklık matrisi



Şekil 4.8. SMOTE algoritması ile dengelenen veri seti ve k-kat çapraz doğrulama yaklaşımı ile eğitilen SVM algoritmasına ait karmaşıklık matrisi

SVM algoritması ile gerçekleştirilen tüm eğitimlere ait performans değerleri çizelge 4.3'te verilmektedir. Sonuçlar incelendiğinde SMOTE algoritmasının performans üzerinde olumlu etkisinin olduğu görülmektedir. SVM algoritması ile gerçekleştirilen eğitimlerin performans analizleri incelendiğinde SMOTE algoritması ile dengeli hale getirilmiş veri seti ile

gerçekleştirilen K-Kat çapraz doğrulama eğitim yaklaşımında en iyi performansı sergilediği görülmektedir.

Çizelge 4.3. SVM algoritması ile gerçekleştirilen eğitimlere ait performans analizleri

	Doğruluk	Kesinlik	Duyarlılık	F1 Ölçütü
Orijinal Veri Seti ve Eğitim ve Test Et Yaklaşımli SVM	0.874	0.871	0.871	0.871
SMOTE Algoritması ile Türetilmiş Veri Seti ve Eğitim ve Test Et Yaklaşımli SVM	0.890	0.890	0.890	0.890
Orijinal Veri Seti ve K-Kat Çapraz Doğrulama Yaklaşımli SVM	0.880	0.876	0.877	0.876
SMOTE Algoritması ile Türetilmiş Veri Seti ve K-Kat Çapraz Doğrulama Yaklaşımli SVM	0.902	0.903	0.903	0.903

4.2. Derin Öğrenme Tabanlı Modeller


4.2.1. Evrişimli sinir ağları

Evrişimli sinir ağları derin öğrenmenin bir alt dalıdır. Genellikle görsel verinin analiz edilmesi için başvurulmaktadır. Sıklıkla kullanıldıkları alanlar; resim ve video teşhisi, önerici sistemlerde görüntü sınıflandırma, tıbbi görüntü analizi ve doğal dil işleme olarak sıralanabilmektedir. CNN'ler, hiyerarşik gösterimleri doğrudan ham veri girişinden otomatik olarak öğrenme yetenekleri nedeniyle görüntü tanıma ve sınıflandırmada yaygın olarak kullanılmaktadır [3]. Genel olarak bir CNN üç tipik katman içerir: Evrişim katmanları, havuz katmanları ve tam bağlantılı katmanlar. Bir evrişim katmanı, ağırlı girdinin farklı bölümleri üzerindeki uzamsal kalıpları algılamasına ve bir havuz katmanının girdinin öteleme değişmezliğini öğrenmesini sağlamaktadır. Tam bağlantılı katmanlar, ağda öğrenme gerçekleştirmek için birkaç evrişim ve havuz katmanından sonra yerleştirilmektedir [3].

Çalışma kapsamında 7 katmanlı sinir ağından oluşan model ile eğitim gerçekleştirilmektedir. Mevcut güncel çalışmaların derlenmesi sonucu sinir ağına ait hiper parametreler ilk halini almaktadır. Sonrasında sinir ağındaki hiper parametreler deneysel yöntemlerle ayarlanmaktadır. Sinir ağı Şekil 4.9'da verildiği gibi son halini almıştır. İki boyutlu evrişim katmanında filtre parametresi 32 olarak ayarlanmaktadır. Filtreler parametresi, o katmandaki evrişimli filtrelerin sayısını ayarlamaktadır. Bu filtreler, belirtilen yöntem kullanılarak küçük, rastgele değerlere ayarlanmaktadır. Sinir ağının eğitimi sırasında, filtreler kaybı en aza indirecek şekilde güncellenmektedir. Bu sayede eğitim boyunca filtreler, kenarlar ve dokular gibi belirli özellikleri algılamayı öğrenmektedirler. Filtre boyutu (kernel size) 3x3

olarak ayarlanmaktadır. Bu parametre filtreler elde edilirken örneklem üzerinde dolaşacak çerçevenin boyutunu ifade etmektedir. Dolgulama (padding) parametresi aynı (same) tercih edilmektedir. Böylece filtrelemeye verilen girdi matrisinin boyutu ile çıktı matrislerinin boyutunun aynı olması sağlanmaktadır. Bu katmandaki son hiper parametre olarak aktivasyon fonksiyonu Relu (Rectified Linear Unit) olarak ayarlanmaktadır. Relu tercih edilmesini sebebi literatürdeki çalışmalarda sıklıkla tercih edilmesinin yanında işlem maliyetinin düşük olmasıdır.

Dense katmanları, düzenli olarak bağlantılı sinir ağı katmanıdır. En yaygın kullanılan ve sıklıkla tercih edilen katmandır. Bu katmanın çıktısı vektörelidir. Birbirine tamamen bağlı olan katman aracılığıyla vektör boyutu giderek azaltılmaktadır. Böylece son aşamada sınıf sayısı boyutunda bir vektör elde edilmektedir. Bu katmanlardaki aktivasyon fonksiyonu hiper parametresi Relu'dur.




Şekil 4.9. Geliştirilen evrişimli sinir ağının gösterimi

Eğitim amacıyla iki farklı yaklaşım denenmektedir: Eğitim test et ve k-Kat yaklaşımı. Geleneksel olarak isimlendirebileceğimiz ilk yaklaşımda oransal olarak bölütlere ayrılan veri seti modelin eğitilmesi için kullanılmaktadır. Ardından test verisi üzerinden tahminleme

yapılarak modelin başarısı ortaya konulmaktadır. K-kat eğitim yaklaşımında ise veri seti k adet parçaya bölünmekte ve her bir parça hem eğitim hem test verisi olarak kullanılmaktadır.

4.2.2. Eğit test et tabanlı eğitim yaklaşımı


Model üzerinde iki farklı eğitim yaklaşımı gerçekleştirilmektedir. İlk yaklaşım olan eğit test et yaklaşımında veri setinin %20'lik kısmı test amaçlı, %80'lik bölümün %20'lik kısmı doğrulama verisi olarak kullanılmaktadır. Veri Setinin geriye kalan kısmı ile de eğitim gerçekleştirilmektedir. Bu eğitim yaklaşımında SMOTE veri seti dengeleme algoritmasının etkisini göstermek amacıyla orijinal veri seti ve dengelenmiş veri seti ile ayrı ayrı denemeler yapılmaktadır. Şekil 4.10 incelendiğinde eğitim aşamasında %83 civarında doğruluk oranına 0,5 kayıp değerine ulaşıldığı görülmektedir.



Şekil 4.10. Eğitim sonucunda elde edilen kayıp değeri ve doğruluk oranı metrikler

Şekil 4.11'de verilen karmaşıklık matrisinden yola çıkılarak çizelge 4.4'te verilen performans değerleri elde edilmektedir. Ayrıca SMOTE veri seti dengeleme algoritması

kullanılmadan sinir ağı modeli eğitildiğinde elde edilen performans değerleri de verilmektedir. İki eğitimdeki değerler karşılaştırıldığında SMOTE algoritması kullanıldığı durumda, kullanılmadığı duruma göre daha iyi performans sergilediği görülmektedir.



Şekil 4.11. Test verisi ile elde edilen karmaşıklık matrisi

Çizelge 4.4. Eğit test et yaklaşımı CNN modelinin eğitimine ait performans analizleri


	Doğruluk	Kesinlik	Duyarlılık	F1 Ölçütü
Eğit test et yaklaşımı CNN Modeli	0.846	0.857	0.841	0.838
SMOTE algoritmalı Eğit test et yaklaşımı CNN Modeli	0.851	0.865	0.850	0.853

Karmaşıklık matrisinden yanlış tahminler incelendiğinde arabaların İHA olarak tahmin edilmesinin diğer yanlış tahminlere göre fazla olduğu görülmektedir. Buna göre veri seti içerisindeki araba ve İHA'lara ait örneklemelerin benzerlik içerdiği düşünülebilir.


4.2.3. K-Kat çapraz doğrulama

İkinci öğrenme yaklaşımı olarak k-kat (k-fold) çapraz doğrulama yaklaşımı kullanılmaktadır. Bu şekilde aynı sinir ağı modeli 5-kat veri seti ile eğitilmektedir. 20, 50, 100 devir sonunda sırasıyla %96,18, %98,24, %99,98 eğitim doğruluğuna ulaşılmaktadır. Şekil 4.12, 4.13 ve 4.14'te eğitime ait devir sayısına göre kayıp ve doğruluk oranı grafikleri verilmektedir. Grafikler göz önüne alındığında tahmin edilebileceği doğrultuda devir sayısının artırılması ile öğrenme başarımları artış göstermektedir. Lakin, devir sayısının


artırılması beraberinde işlem maliyeti de getirmektedir. Grafikler incelendiğinde öğrenme ivmesi belli bir devir sayısından sonra azalmaktadır. Bu aşamada işlem maliyetini göz önüne alındığında 50 devirli eğitimin pratikte yeterli olabileceği değerlendirilebilir.



Şekil 4.12. 5-Kat yaklaşımı ile 20 devir eğitilmiş modele ait kayıp değeri ve doğruluk oranı grafiği



Şekil 4.13. 5-Kat yaklaşımı ile 50 devir eğitilmiş modele ait kayıp değeri ve doğruluk oranı grafiği




Şekil 4.14. 5-Kat yaklaşımı ile 100 devir eğitilmiş modele ait kayıp değeri ve doğruluk oranı grafiği

K-kat çapraz doğrulama yaklaşımında katların benzer değerleri sahip olması modelin tutarlılığı açısından kritiktir. Bu sayede modelin her koşulda başarımlı olduğunu gösterdiğinden emin olunabilmektedir. Çizelge 4.5'te katların elde ettiği doğruluk oranları, kayıp değerleri ve

katların ortalaması verilmektedir. Sonuçlar incelendiğinde katların birbirine yakın değerlere sahip olduğu görülebilmektedir. Katlara ait değerler arasında büyük bir fark bulunmaması modelin ve eğitim yaklaşımının tutarlı olduğunu göstermektedir.

Çizelge 4.5. 5-Kat çapraz doğrulama sonucunda tüm katlara ait elde edilen değerler

Kat Numarası	Doğruluk Oranı	Kayıp Değeri
1	0,994	0,0151
2	0,999	0,0003
3	0,990	0,0292
4	0,996	0,0004
5	0,999	0,0004
Ortalama	0,997	0,0009



Şekil 4.15. K-kat çapraz doğrulama yaklaşımı CNN modeline ait test verisi ile elde edilen karmaşıklık matrisi


Şekil 4.15'te verilen karmaşıklık matrisinden yola çıkılarak çizelge 4.6'da verilen performans değerleri elde edilmektedir. Orijinal veri seti ile sinir ağı modeli eğitildiğinde elde edilen performans değerleri de verilmektedir. İki eğitimdeki değerler karşılaştırıldığında SMOTE algoritması kullanıldığı durumda, kullanılmadığı duruma göre

daha iyi performans sergilediği görülmektedir.

Çizelge 4.6. K-kat çapraz doğrulama yaklaşımı CNN modelinin eğitimine ait performans analizleri

	Doğruluk	Kesinlik	Duyarlılık	F1 Ölçütü
K-kat çapraz doğrulama yaklaşımı CNN Modeli	0.884	0.892	0.875	0.875
SMOTE algoritmali K-kat çapraz doğrulama yaklaşımı CNN Modeli	0.962	0.962	0.962	0.962

Şekil 4.16'da rastgele seçilmiş olan 15 örnek ve 100 devir eğitilmiş model tarafından gerçekleştirilen tahminler verilmektedir. Örneklerin yüksek doğruluk oranları ile tahmin edildiği görülmektedir.



Şekil 4.16. Rastgele seçilmiş 15 örneğe ait tahmin sonuçları

5. SONUÇ VE ÖNERİLER

Radar donanımları keşif ve gözetleme sistemlerinde sıklıkla başvurulanan donanımlardandır. Sivil ve askeri alanlarda erken ihbar yeteneğinin temel unsuru olmasının yanında, hedef tespiti, takibi ve sınıflandırma konularında oldukça başarılı donanımlardır.

Radar teknolojisi, performans ve sistem gereksinimleri göz önüne alındığında tercih edilen yöntem ve yaklaşımlar farklılık göstermektedir. Genellikle derin öğrenme tabanlı yaklaşımların tercih edildiği söylenebilir. Birçok çalışmada başarısını kanıtlamış olan derin öğrenme tabanlı yaklaşımlar radar teknolojilerinde bu açıdan kendine yer bulmuş durumdadır.

SVM, rastgele orman, k-NN ve karar ağacı algoritmaları, incelenen çalışmalarda öne çıkan öğrenme yaklaşımlarındandır. Birçok çalışmada derin öğrenme tabanlı yöntemlere alternatif olarak sunulan algoritmalar, özellikle zaman kritik olan ve yüksek işlem maliyetini karşılayamayacak sistemlerde kullanımı önerilmektedir. Uygun ön işleme ve nitelik çıkarım yöntemleri ile beraber kullanıldıklarında bu algoritmaların da derin öğrenme tabanlı yaklaşımlar kadar yüksek başarımlar gösterdikleri görülmektedir.

Roldan ve diğerleri (2020) tarafından halka açık olarak sunulan doppler radar veri seti ile hedef sınıflandırma çalışması gerçekleştirilmiştir. Bu konu kapsamında sıklıkla tercih edilen sınıflandırma yaklaşımları ele alınmıştır.

Bu amaçla öncelikle mevcut veri seti ve ön işleme tekniklerini kullanarak makine öğrenmesi tabanlı yöntemlerle derin öğrenme tabanlı yöntemlerle karşılaştırmak amacıyla deneysel çalışmalar gerçekleştirilmiştir. Bunun sonucunda Çizelge 5.1’de toparlanmış olan performans metrikleri elde edilmiştir. Rastgele orman ve SVM algoritması ile gerçekleştirilen deneysel çalışmalarda yüksek doğruluk değerleri elde edilmiştir. Veri setinin dengeli hale getirilmesi ve k-kat çapraz doğrulama yaklaşımının bu yöntemler üzerinde pozitif etkisinin olduğu görülmüştür.

Deneysel çalışma kapsamında derin öğrenme tabanlı bir çözüm ortaya koymak amacıyla Şekil 4.9’da özetlenen bir sinir ağı modellenmiştir. Çalışma [15]’te kullanılan halka açık veri seti, SMOTE algoritması ile dengeli hale getirildikten sonra geliştirilen sinir ağı iki farklı şekilde eğitilmiştir. Eğitim test et yaklaşımıyla eğitilen model %82 eğitim doğruluğuna ulaşmıştır. Test verisi ile elde edilen karmaşıklık matrisi doğrultusunda %81 civarında doğruluğa ulaşıldığı görülmüştür. İkinci eğitim yaklaşımı olarak k-kat çapraz doğrulama

yöntemi kullanılmıştır. Bu yöntemde 5 parçaya bölünen veri setinin her bir parçasının test, geri kalan kısmının ise eğitim seti olarak kullanılmasıyla 5 kez eğitilmesi sağlanmıştır. Bu yöntemle aynı sinir ağı modeli eğitildiğinde %99,98 doğruluğa ulaşılmıştır.

Sonuçlar incelendiğinde veri setinin dengeli hale getirilmesi model başarımını genel olarak iyileştirmiştir. Eğitim yaklaşımı olarak durum incelendiğinde de k-kat çapraz doğrulama yaklaşımının eğit test et yaklaşımına nazaran daha iyi performans sergilediği söylenebilir. Test edilen sınıflandırıcı algoritmalar içinde ise önerilen CNN modelinin en yüksek doğruluğa sahip olduğu Çizelge 5.1'deki metriklerden anlaşılabilmektedir. Bu durum sınıflandırıcı algoritmalar içerisinde derin öğrenme tabanlı yöntemlerin tercih edilmesini destekler niteliktedir.

Çizelge 5.1. Deneysel çalışma kapsamında elde edilen performans metrikleri ve sonuçları

	Doğruluk	Kesinlik	Duyarlılık	F1 Ölçütü
Dengeli Rastgele Orman	0.907	0.904	0.907	0.904
Orijinal Veri Seti ve Eğitim ve Test Et Yaklaşımlı SVM	0.874	0.871	0.871	0.871
SMOTE Algoritması ile Türetilmiş Veri Seti ve Eğitim ve Test Et Yaklaşımlı SVM	0.890	0.890	0.890	0.890
Orijinal Veri Seti ve K-Kat Çapraz Doğrulama Yaklaşımlı SVM	0.880	0.876	0.877	0.876
SMOTE Algoritması ile Türetilmiş Veri Seti ve K-Kat Çapraz Doğrulama Yaklaşımlı SVM	0.902	0.903	0.903	0.903
Eğit test et yaklaşımı CNN Modeli	0.846	0.857	0.841	0.838
SMOTE algoritmali Eğitim test et yaklaşımı CNN Modeli	0.851	0.865	0.850	0.853
K-kat çapraz doğrulama yaklaşımı CNN Modeli	0.884	0.892	0.875	0.875
SMOTE algoritmali K-kat çapraz doğrulama yaklaşımı CNN Modeli	0.962	0.962	0.962	0.962

2020 yılında Roldan ve diğerlerinin radar veri setinin sunuldukları çalışmalarında geliştirdikleri DopplerNet isimli CNN modelini test etmektedirler. Bunun yanında karşılaştırma yapmak amacıyla aynı çalışmada NasNetMobile ve MobileNetV2 sinir ağı modelleri aynı veri seti ile test edilerek sonuçları karşılaştırılmaktadır. Çalışmada elde etmiş

oldukları sonuçlar çizelge 5.2’de verilmektedir. Literatürdeki yaklaşımlar ve sonuçlar incelendiğinde gerçekleştirilen deneysel çalışma sonuçları daha iyi performans göstermesinin yanında benzerlik göstermektedir. Bu durum gerçekleştirilen çalışmanın literatürdeki sonuçları destekler nitelikte olduğunu göstermektedir.

Çizelge 5.2. Deneysel çalışmalarda kullanılan veri seti ile literatürde gerçekleştirilen çalışmaların sonuçları ve önerilen sinir ağı modeli ile elde edilen sonuç

Model	Doğruluk Oranı
DopplerNet [15]	%99,48
NasNetMobile [15]	%97,67
MobileNetV2 [15]	%98,94
Önerilen CNN	%99,65

Önerilen CNN modeli ve makine öğrenmesi tabanlı yaklaşımların sonuçları karşılaştırıldığında önerilen CNN modelinin daha başarılı olduğu görülmektedir. Bu durumda önerilen modelin literatürdeki diğer sinir ağı modellerinden daha başarılı olmasının yanında makine öğrenmesi tabanlı yöntemlerden de daha başarılı olduğu görülmektedir.

Bunların sonucunda önerilen CNN modeli ile radar verisiyle nesne sınıflandırma yapılarak İHA’ların tespit edilmesinde hata oranı daha düşük hale getirilmiştir. İki yaklaşıma ait sonuçlar incelendiğinde k-kat çapraz doğrulama yönteminin daha başarılı olduğu söylenebilir. Eğitim süresi göz önüne alındığında bu yöntemin daha maliyetli olduğu bilinmektedir. Ancak devir sayısının ilk yönteme nazaran daha düşük olduğu denemelerde bile daha yüksek doğruluk elde edildiği grafiklerden anlaşılabilmektedir.

İleriki aşamalarda mevcut parametrelerin değiştirilmesi ile aynı doğruluğa daha az maliyetle erişmek üzerine çalışma yapılabilir. K-kat çapraz doğrulama yöntemi kadar başarılı ancak maliyet yönünden daha az masraflı yöntemlerin tespit edilmesi amaçlanabilir. Farklı donanımlardan elde edilen verilerle oluşturulacak doppler radarı veri setleriyle mevcut yöntemin genel geçerliliğini sorgulayacak çalışmalar gerçekleştirilebilir. Bu sayede yöntemin zayıf noktaları belirlenebilir ve ileride karşılaşılmaması muhtemel zorluklarla önceden başa çıkılabilir. Gerçek dünya senaryolarında karşılaşılabileceği üzere,

problemin zorluğunu artıracak yöntemlerle (gürültü ekleme, dengesizliği artırma, vb.) mevcut veri seti ile geliştirilen modelin gelişime açık noktaları belirlenebilir.

KAYNAKLAR

1. Torvik, B., Olsen, E. and Griffiths H. (2016). Classification of birds and UAVs based on radar polarimetry. *IEEE Geoscience and Remote Sensing Letters*, 13(9), 13005-1309.
2. Manno-Kovacs, A., Giusti, E., Berizzi, F. and Kovács, L. (2019). Image based robust target classification for passive ISAR. *IEEE Sensors Journal*, 19(1), 268-276.
3. Luo, F., Poslad, S. and Bodanese, E. (2019). Human activity detection and coarse localization outdoors using micro-doppler signatures. *IEEE Sensors Journal*, 19(18), 8079-8094.
4. Angelov, A., Robertson, A., Murray-Smith, R. and Fioranelli, F. (2018). Practical classification of different moving targets using automotive radar and deep neural networks. *IET Radar, Sonar & Navigation*, 12(10), 1082-1089.
5. Mou, X., Chen, X., Su, N. and Guan, J. (2019). Motion classification for radar moving target via STFT and convolution neural network. *The Journal of Engineering*, 19(6), 6287-6290.
6. Oh, B., Guo, X., Wan, F., Toh, K. and Lin, Z. (2018). Micro-doppler mini-UAV classification using empirical-mode decomposition features. *IEEE Geoscience and Remote Sensing Letters*, 15(2), 227-231.
7. Huizing, A., Heiligers, M., Dekker, B., de Wit, J., Cifola, L. and Harmanny, R. (2019). Deep learning for classification of mini-UAVs using micro-doppler spectrograms in cognitive radar. *IEEE Aerospace and Electronic Systems Magazine*, 34(11), 46-56.
8. Fioranelli, F., Ritchie, M., Gürbüz, S. Z. and Griffiths H. (2017). Feature diversity for optimized human micro-doppler classification using multistatic radar. *IEEE Transactions on Aerospace And Electronic Systems*, 53(2), 640-654.
9. Will, C., Vaishnav, P., Chakraborty, A. and Santra, A. (2019). Human target detection, tracking, and classification using 24-Ghz FMCW radar. *IEEE Sensors Journal*, 19(17), 7283-7299.
10. Chen, S., Wang, H., Xu, F. and Jin, Y. (2016). target classification using the deep convolutional networks for SAR images. *IEEE Transactions on Geoscience And Remote Sensing*, 54(8), 4806-4817.
11. Chang, M., You, X. and Cao, Z. (2019). Bidimensional Empirical Mode Decomposition for SAR Image Feature Extraction With Application to Target Recognition. *IEEE Access*, 7(1), 135720-135731.
12. Zhu, H., Wang, W. and Leung, R. (2020). SAR target classification based on radar image luminance analysis by deep learning. *IEEE Sensors Letters*, 4(3), 1-4.
13. Wand, J., Zheng, T., Leia, P. and Bai, X. (2018). Ground target classification in noisy SAR images using convolutional neural networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(11), 4180-4192.

14. Bentes, C., Velotto, D. and Tings, B. (2018). Ship classification in TerraSAR-x images with convolutional neural networks. *IEEE Journal of Oceanic Engineering*, 43(1), 258-266.
15. Roldan, I., del-Blanco, C., Duque de Quevedo, Á., Ibañez Urzaiz, F., Gismero Menoyo, J., Asensio López, A., Berjón, D., Jaureguizar, F. and García, N., (2020). DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range–Doppler radar. *IET Radar, Sonar & Navigation*, 14(4), 593-600.
16. Liu, W., Zhang, M., Luo, Z. and Cai, Y. (2017). An ensemble deep learning method for vehicle type classification on visual traffic surveillance sensors. *IEEE Access*, 5(1), 24417-24425.
17. Wang, J., Zheng, H., Huang, Y. and Ding, X. (2018). Vehicle type recognition in surveillance images from labeled web-nature data using deep transfer learning. *IEEE Transactions on Intelligent Transportation Systems*, 19(9), 2913-2922.
18. Anala, M. R., Makker, M. and Ashok, A. (2019, December). *Anomaly Detection in Surveillance Videos*. Paper presented at the 26th International Conference on High Performance Computing, Data and Analytics Workshop, Hyderabad.
19. Nasaruddin, N., Muchtar, K. and Afdhal, A. (2019). A lightweight moving vehicle classification system through attention-based method and deep learning. *IEEE Access*, 7(1), 157564-157573.
20. Kim, Y. and Moon, T. (2016). Human detection and activity classification based on micro-doppler signatures using deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 13(1), 8–12.
21. Jokanovic, B. and Amin, M. (2018). Fall detection using deep learning in range-doppler radars. *IEEE Transactions on Aerospace and Electronic Systems*, 54(1), 180–189.
22. Seyfioglu, M. S. and Gurbuz, S. Z. (2017). Deep neural network initialization methods for micro-doppler classification with low training sample support. *IEEE Geoscience and Remote Sensing Letters*, 14(12), 2462–2466.
23. Briones, J. C., Flores, B. and Cruz-Cano, R. (2012). Multi-mode radar target detection and recognition using neural networks. *International Journal of Advanced Robotic Systems*, 9(5), 177.
24. Kouba, E. T. (1992). *Recurrent neural networks for radar target identification*. Ph.D. thesis, Air University, Alabama.
25. Pramudita, A. A., Lukas, L. and Ewer, E. (2020). Time and frequency domain feature extraction method of doppler radar for hand gesture based human to machine interface. *Progress In Electromagnetics Research C*, 98, 83-96.
26. Kizhakkal, V. (2013). *Pulsed radar target recognition based on micro-doppler signatures using wavelet analysis*. Master's Thesis, The Ohio State University, Columbus, Ohio.

27. Gray, J. E., and Brastrom, P. (2002, April). *The problem of kill assessment part ii the doppler effect and exo-atmospheric kill assessment*. Paper presented at the Proceedings of the 2002 IEEE Radar Conference, California.
28. Chappell, S. K., Alounai, A. T., Rice, T. R. and Gray, J. E. (1992, September). *Partial determination of particle motion using artificial neural networks*. Paper presented at the first IEEE Conference on Control Applications, Dayton, Ohio.
29. Priddy, K. L. and Keller, P. E. (2005). *Artificial neural networks: an introduction* (Second edition). USA: SPIE-International Society for Optical Engine, 78-81.
30. Alpaydın, E. (2014). *Introduction to machine learning* (Third edition). England: The MIT Press, 56.
31. Kozak, J. (2019). *Decision tree and ensemble learning based on ant colony optimization* (First edition). Poland: Springer International Publishing, 98-100.
32. Singh, S. and Gupta, P. (2014). Comparative study ID3, CART and C4.5 decision tree algorithm: a survey. *International Journal of Advanced Information Science and Technology*, 3(7), 47-52.
33. Ho, T. K. (2001). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8), 832-844.
34. Paul, A., Mukherjee, D. P., Das, P., Gangopadhyay, A., Chintha, A. R. and Kundu, S. (2018). Improved random forest for classification. *IEEE Transactions on Image Processing*, 27(8), 4012-4024.
35. Bishop, C. M. (2006). *Pattern recognition and machine learning* (Second edition). USA: Springer, 76-77.
36. Gökduman R.S. (2022), *Makine öğrenmesi yöntemleri ile imha değerlendirme*. Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara (18-20).
37. Gülüdoğan E., (2017), *Çeşitli çekirdek fonksiyonları ile oluşturulan destek vektör makinesi modellerinin performanslarının incelenmesi: bir klinik uygulama*. Doktora Tezi, İnönü Üniversitesi, Malatya (15-17).
38. Hsu, C. W. and Lin, C. J. (2002). A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 13(2), 415-425.
39. Mackay, D. J. C, (2003). *Information theory, inference, and learning algorithms* (First edition). United Kingdom: Cambridge University Press, 152-154.
40. Lang, P., Fu, X., Martorella, M., Dong, J., Qin, R., Meng, X. and Xiei M. (2020). Comprehensive survey of machine learning applied to radar signal processing. *arXiv: Signal Processing*, 78(1), 1603-1611.
41. Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408.

42. Tang, J., Deng, C. and Huang, G. B. (2016). Extreme learning machine for multilayer perceptron. *IEEE Transactions on Neural Networks and Learning Systems*, 27(4), 809–821.
43. Kumawat, S., Verma, M., Nakashima, Y. and Raman, S. (2021). Depthwise Spatio-Temporal STFT Convolutional Neural Networks for Human Action Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(9), 4839 – 4851.
44. He, H., & Ma, Y. (2013). *Imbalanced Learning: Foundations, Algorithms, and Applications* (First edition). United Kingdom: Wiley, 128-131.
45. Batista, G. E., Prati, R. C. and Monard, M. C. (2004). A study of the behavior of several methods for balancing machine learning training data. *ACM SIGKDD Explorations Newsletter*, 6(1), 20–29.
46. Wang, J., Xu, M., Wang, H., & Zhang, J. (2006). *classification of imbalanced data by using the SMOTE algorithm and locally linear embedding*. Paper presented at 8th International Conference on Signal Processing, Guilin, China.
47. Yao, P., Shen, S., Xu, M., Liu, P., Zhang, F., Xing, J., Shao, P., Kaffenberger, B. and Xu, R. X. (2022). Single model deep learning on imbalanced small datasets for skin lesion classification. *IEEE Transactions on Medical Imaging*, 41(5), 1242–1254.
48. Vakili, M., Ghamsari, M. H. N. and Rezaei, M. (2020). Performance analysis and comparison of machine and deep learning algorithms for iot data classification. *ArXiv: Computer Science, Mathematics*, 9(1), 506-513.
49. Hu, L., Zhang, J., Xiang, Y. and Wang, W. (2020). Neural networks-based aerodynamic data modeling: a comprehensive review. *IEEE Access*, 8(1), 90805–90823.
50. Mairal, J., Koniusz, P., Harchaoui, Z. and Schmid, C. (2014). Convolutional kernel networks. *Neural Information Processing Systems*, 27, 2627–2635.
51. Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *ArXiv: Learning*, 9(1), 208-214.
52. Zhang, X., Zhao, J. and LeCun, Y. (2015). Character-level convolutional networks for text classification. *Advances in Neural Information Processing Systems*, 649-657.
53. Polat, K. (2019). A Hybrid Approach to Parkinson Disease Classification Using Speech Signal: The Combination of SMOTE and Random Forests. *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science*, 1-3.
54. Feng, W., Huang, W. and Bao, W. (2019). Imbalanced hyperspectral image classification with an adaptive ensemble method based on SMOTE and rotation forest with differentiated sampling rates. *IEEE Geoscience and Remote Sensing Letters*, 16(12), 1879–1883.
55. Wei, J., Lu, Z., Qiu, K., Li, P. and Sun, H. (2020). Predicting drug risk level from adverse drug reactions using SMOTE and machine learning approaches. *IEEE Access*, 8(1), 185761–185775.

56. Cai, X., Giallorenzo, M. and Sarabandi, K. (2021). Machine learning-based target classification for MMW radar in autonomous driving. *IEEE Transactions on Intelligent Vehicles*, 6(4), 678–689.
57. Liu, J., Xu, Q. Y. and Chen, W. S. (2021). Classification of bird and drone targets based on motion characteristics and random forest model using surveillance radar data. *IEEE Access*, 9(1), 160135–160144.
58. Bi, H., Deng, J., Yang, T., Wang, J. and Wang, L. (2021). CNN-based target detection and classification when sparse SAR image dataset is available. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14(1), 6815–6826.
59. Kanona, M. E. A., Alias, M. Y., Hassan, M. K., Mohamed, K. S., Khairi, M. H. H., Hamdan, M., Hamdalla, Y. A., Osman, O. M. and Ahmed, A. M. O. (2022). A Machine Learning Based Vehicle Classification in Forward Scattering Radar. *IEEE Access*, 10(1), 64688–64700.
60. Arab, H., Ghaffari, I., Chioukh, L., Tatu, S. O. and Dufour, S. (2022). A convolutional neural network for human motion recognition and classification using a millimeter-wave doppler radar. *IEEE Sensors Journal*, 22(5), 4494–4502.
61. Sabery, S. M., Bystrov, A., Gardner, P., Stroescu, A. and Gashinova, M. (2021). Road surface classification based on radar imaging using convolutional neural network. *IEEE Sensors Journal*, 21(17), 18725–18732.
62. Jansen, R. W. and Raj, R. G. (2022). MSAR-Net: A Deep learning based classification approach for learning the maritime environment. *IEEE Transactions on Geoscience and Remote Sensing*, 60(1), 1–9.



Gazili olmak ayrıcalıktır