

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

**FMCW RADAR VERİLERİNİN MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE SINIFLANDIRILMASI**

HAZIRLAYAN

EMRE CAN ERTEKİN

YÜKSEK LİSANS TEZİ

ANKARA – 2024

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

**FMCW RADAR VERİLERİNİN MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE SINIFLANDIRILMASI**

HAZIRLAYAN

EMRE CAN ERTEKİN

YÜKSEK LİSANS TEZİ

**TEZ DANIŞMANI
DOÇ. DR. SELDA GÜNEY**

ANKARA – 2024

ANKARA – 2024
BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Emre Can ERTEKİN tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 23/08/2024

Tez Adı: : FMCW Radar Verilerinin Makine Öğrenmesi Yöntemleri İle Sınıflandırılması

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

Prof. Dr. Hamit Erdem, Başkent Üniversitesi	
---	-------

Dr. Öğr. Üyesi Koray Açıcı, Ankara Üniversitesi	
---	-------

Doç. Dr. Selda Güney, Başkent Üniversitesi	
--	-------

ONAY

Prof. Dr. Dilek Çökeliler Serdaroğlu
Fen Bilimleri Enstitüsü Müdürü

Tarih: / / 2024

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 06/09/2024

Öğrencinin Adı, Soyadı : Emre Can ERTEKİN

Öğrencinin Numarası : 22120005

Anabilim Dalı : Elektrik-Elektronik Mühendisliği

Programı : Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı : Doç. Dr. Selda Güney

Tez Başlığı : FMCW Radar Verileri Kullanılarak Nesnelerin Derin Öğrenme Tabanlı Bir Yöntem İle Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 75 sayfalık kısmına ilişkin, 06 / 09 / 2024 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %8'dir.

Uygulanan filtrelemeler:

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

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

Öğrenci İmzası:

ONAY

Öğrenci Danışmanı

Doç. Dr. Selda Güney

Tarih: ... / ... / 20...

TEŞEKKÜR

Tez çalışmam süresince ve yüksek lisans eğitimim boyunca her adımda yanımda olan, bana rehberlik eden ve yol gösteren değerli tez danışmanım Doç. Dr. Selda Güney'e en içten teşekkürlerimi sunarım. Ayrıca, hayatım boyunca bana her türlü desteği sağlayan, her zaman yanımda olan ve beni cesaretlendiren sevgili aileme minnettarım. Bu yolculukta gösterdikleri sabır ve anlayış için onlara sonsuz teşekkür ederim.



ÖZET

Emre Can ERTEKİN

FMCW RADAR VERİLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2024

Günümüzde objeleri niteliklerine göre sınıflandırmanın birçok uygulama alanı bulunmaktadır. Örneğin, savunma sanayi, gözetleme, robotik vb. Bu durum, geleneksel yöntem ile çözülemeyen problemlere yönelik birçok yenilikçi uygulamanın ortaya çıkmasına olanak sağlar. Örneğin, radar verileri üzerinden nesnelerin sınıflandırılmasında hız, Radar Kesit Alanı (RKA), faz değişimi gibi birçok değer göz önünde bulundurulur. Ancak, bu yöntem ile birbirine yakın boyut ve hızlarda olan nesneler yüksek doğruluk ile ayırt edilememektedir. Bu duruma örnek olarak kuş ve dronelerin radar verileri üzerinden ayırt edilmeye çalışılmasını örnek verebiliriz. Kuşlar ve dronelerin RKA ölçümleri ve hızları bazı durumlarda aynı olmaktadır ve bu sebep ile geleneksel eşik uygulama gibi yöntemler etkin olmamaktadır. Günümüzde meydana gelen simetrik ve asimetrik çatışma ve savaşlar göz önüne alındığında, drone kullanımının arttığını ve savaş alanında etkin bir şekilde kullanılabileceğini gözlemlemek mümkündür. Dronelerin kolay elde edilebilir ve kolay imal edilebilir olması bu duruma neden olabilmektedir. Bu nedenle farklı sensörler ve farklı yöntemler kullanılarak bu dronelerin ayırt edilmesi önem arz etmektedir. Bu tez çalışmasında, bu ayrımın yüksek performansla gerçekleştirilebilmesi için gerçek radar sensör ölçümlerinden elde edilen eş evreli dördün evreli (In-Phase Quadrature, IQ) verilerinin spektogramları ile Evrışimsel Sinir Ağı(ESA) algoritmasının performansı üzerine

bir çalışma yapılmıştır. Bu çalışmada, Frekans Modülasyonlu Sürekli Dalga (Frequency Modulated Continuous Wave, FMCW) radardan elde edilmiş olan IQ verilerinin mikrodoppler izlerini kullanarak, klasik makine öğrenmesi yöntemlerini ve farklı derin öğrenme mimarilerini kullanarak hem farklı drone türlerinin sınıflandırılmasını hem de dronelerin kuşlardan ayırt edilmesi gerçekleştirilmiştir. Bu çalışmada kullanılmış olan veriseti içerisinde 6 adet drone sınıfı, 2 adet insan hareketine bağlı ölçümlerden oluşan insan sınıfı, 6 ayrı kuş türüne ait ölçümlerin olduğu kuş sınıfı ve Üçgen Reflektör ölçümlerinden oluşan üçgen reflektör sınıfı bulunmaktadır. Bu çalışma sonucunda uçtan uca oluşturulmuş ESA mimarileri ve önceden eğitilmiş ESA mimarilerinde ile yüksek başarımlar elde edilmiştir. Bu çalışmada önerilen ESA mimarisi ile özneteliklerin çıkartılarak Destek Vektör Makinası ile sınıflandırıldığında en yüksek doğruluk değeri %98.04 olarak elde edilmiştir.

ANAHTAR KELİMELELER: Destek Vektör Makineleri, Evrimsel Sinir Ağları, Kuş Sınıflandırma, Drone Sınıflandırma

ABSTRACT

Emre Can ERTEKİN

Classification Of Targets By Using FMCW Radar Data With Machine Learning

Methods

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2024

Nowadays, object classification has many applications field, such as defense, surveillance, robotics etc. This situation brings so many solutions for problems in traditional classification methods. For example, many values such as speed, Radar Cross Section (RCA), and phase change are taken into account when classifying objects from radar data. However, with usage of this method has bad accuracy in case of similar RCS and speed targets. For example, in case of birds and drones their size and speeds are similar in many cases. Because of this, classification of bird and drone has poor accuracy when using traditional classification methods (Thresholding etc.). In case of drone-bird classification, those algorithms have lack of accuracy. Since, size of a drone and birds are nearly same, RCS classifications cannot work properly. Considering the symmetrical and asymmetrical conflicts and wars taking place today, it is possible to observe that the use of drones is increasing and can be used effectively in these areas. The fact that drones can be easily obtained and easily manufactured can cause this situation. The importance of classifying and distinguishing between drones and birds is important both on the battlefield and in protecting high-value sites and infrastructure from terrorist attacks. For example, airports, military bases, military convoys, government buildings, nuclear power plants, power stations, dams, etc. For this reason, it is important to distinguish these drones using different sensors and different

methods. In order to realize this discrimination with high performance, this study is used a real radar sensor measured In-Phase Quadrature (IQ) data spectrograms to observing performance of Convolutional Neural Network (CNN) algorithms. In this thesis study, using micro-Doppler traces of IQ data obtained from FMCW radar, classical machine learning methods and different deep learning architectures have been used to classify different drone types and to distinguish drones from birds. To conduct this study, two datasets is used, first dataset consist of 6 drone classes, 2 human classes with different movements, 6 different bird classes and 1 corner reflector class were used. In second dataset, only drones and bird measurements were used. As a result of this study, high accuracy rates were obtained with end-to-end CNN architectures and Pre-trained CNN architectures. With the CNN architecture proposed in this study, the highest accuracy value 98.04 % was obtained when features were extracted and classified with Support Vector Machine (SVM) with the usage of nine class dataset. With the usage of second dataset which is include only two class (Birds and drones) the accuracy is 99.4 % with the same CNN feature extraction and SVM method use.

KEYWORDS: Support Vector Machines, Convolutional Neural Networks, Bird Classification, Drone Classification

ÖNSÖZ

Günümüzde drone platformlarının kolay erişilebilirliği ve basit yapıları ile hem askeri hem de sivil alanlarda kullanımı giderek artmaktadır. Bu durumun en büyük örneği günümüzde gerçekleşen savaşlar ve terör saldırılarında dronelar vasıtası ile yapılan saldırılardır. Bu sebep ile bu drone platformlarının farklı sensörler vasıtası ile tespitleri, teşhisleri önem arz etmektedir. Bu tez çalışmasında, bu durumun önemi dikkate alınarak 77 GHz FMCW radar sisteminden elde edilmiş IQ veriler kullanılarak hedeflere ait mikro-doppler izleri üzerinden bu tarz platformların sınıflandırılmasına yönelik farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak analizler gerçekleştirilmiştir. Yapılan bütün deneylerin analizleri incelenerek en yüksek başarı kriterine sahip algoritma bu sınıflandırma problemi için önerilmiştir. Bu tez çalışmasının gerçekleştirilebilmesi ve geliştirilebilmesi hususunda rehberliğinden dolayı Doç. Dr. Selda Güney'e teşekkürlerimi sunarım.

İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
1.1. Çalışmanın Amacı.....	2
1.2. Tezin Organizasyonu	2
2. RADAR VERİLERİ VE DERİN ÖĞRENME.....	3
3. LİTERATÜRDEKİ ÇALIŞMALAR	5
4. KULLANILAN VERİ SETİ	7
5. KULLANILAN SINIFLANDIRMA ALGORİTMALARI.....	11
5.1 Makine Öğrenmesi.....	11
5.1.1 Denetimli Makine Öğrenmesi	12
5.1.2 Denetimsiz Makine Öğrenmesi	12
5.1.3 Pekiştirmeli Makine Öğrenmesi	12
5.2 Derin Öğrenme Algoritmaları	13
5.3 Evrişimsel Sinir Ağları	13
5.4 Klasik Makine Öğrenmesi Yöntemleri	15
5.5 Başarım Kriterleri	17
6. UYGULANAN YÖNTEMLER	17
6.1 Radar verisinin Ön İşlemesi.....	18

6.2 Algoritmada Kullanım için Veri setinin Tekrar Organize Edilmesi	21
6.3 Kullanılan ESA yapısı	22
6.4 Sınıflandırma	22
6.4.1 Girdi Boyutlarına Göre Gerçekleştirilen Çalışmalar	26
6.4.2 Adaptif Öğrenme Algoritmaları	29
6.4.3 ESA Filtre Boyutlarına Yönelik Denemeler	33
6.4.4 ESA Katman Sayısı Üzerinde Yapılan Denemeler	35
6.4.5 Önceden Eğitilmiş Sinir Ağlarının Başarımları	39
6.4.6 Klasik Makine Öğrenmesi Yöntemlerinin Kullanılması	42
6.4.7 Sınıflandırma Yöntemlerinin Başarımlarının Karşılaştırılması	47
7. SONUÇ VE ÖNERİLER	53
KAYNAKLAR	55

TABLÖLAR LİSTESİ

Sayfa

Tablo 4-1 Radar Parametreleri[13].....	7
Tablo 4-2 Veri setinde yer alan sınıflar	8
Tablo 4-3 Veri seti içerisinde yer alan sınıfların dağılımları.....	8
Tablo 6-1 Tek tarama segmenti ve Beş Tarama segmentine yönelik başarımlar.....	25
Tablo 6-2 İki sınıflı verilere ait eğitim ve test başarımları.	26
Tablo 6-3 Girdi boyutlarına göre test ve eğitim başarımları.	29
Tablo 6-4 Adaptif Öğrenme Algoritmalarının Eğitim ve Test Başarımları	33
Tablo 6-5 Filtre boyutlarına göre elde edilen test ve eğitim başarımları.....	35
Tablo 6-6 ESA katman yapılarına göre eğitim ve test başarımları.....	38
Tablo 6-7 İki sınıflı veriseti ile 6 katmanlı ESA başarımları.	39
Tablo 6-8 Önceden Eğitilmiş Sinir Ağları ile elde edilmiş Test ve Eğitim başarımları.....	40
Tablo 6-9 Resnet50 ile iki sınıflı verilerin kullanılması durumunda elde edilen sonuçlar..	42
Tablo 6-10 Klasik Makine Öğrenmesi algoritmaları ile elde edilen başarımlar.	44
Tablo 6-11 İki sınıflı veriseti ile Lineer DVM başarımları.	46
Tablo 6-12 Sınıflandırma için kullanılan yöntemlerin karşılaştırması.....	47
Tablo 6-13 Benzer çalışmalar ile tez çalışmasının başarımlar karşılaştırması.	51
Tablo 6-14 İki sınıflı veri seti ile elde edilmiş sonuçlar.	52

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2-1 ZION Market Research firmasının, drone pazar büyüklüğü tahmini.[11].....	4
Şekil 4-1 a. "Drone 1" sınıfına ait IQ veri. b. "Kuş" sınıfına ait bir IQ veri.....	9
Şekil 4-2 Veri seti ağaç diyagramı.	10
Şekil 5-1 Yapay zeka algoritmalarının alt dalları.....	11
Şekil 5-2 Makine Öğrenmesi Öğrenme Türleri[18]	12
Şekil 5-3 Evrişim, öznitelik çıkartımı.[21].....	14
Şekil 5-4 İki farklı havuzlama yöntemi.[21]	15
Şekil 5-5 Karar Ağacı yapısı.	16
Şekil 5-6 DVM yapısı.[26]	16
Şekil 6-1 “Drone 1” sınıfına ait, bir ölçümde yer alan beş tarama segmentine ait spektogram gösterimi.....	19
Şekil 6-2 Bütün sınıflara ait örnek 5 tarama segmentli bir spektogram görüntüsü.	20
Şekil 6-3 Çalışma kapsamında ölçümlere ait sınıfların tekrar organize edilmesi.	21
Şekil 6-4 Kullanılan temel 5 Katmanlı ESA yapısı.....	22
Şekil 6-5 100x100 Girdi Boyutu ile elde edilen eğitim sonucu	23
Şekil 6-6 100x100'lük girdi boyutu ile elde edilen sınıflandırma sonucu.	23
Şekil 6-7 Tek tarama segmentine ait 100x100'lük girdi boyutu ile eğitim sonucu.....	24
Şekil 6-8 Tek tarama segmentine ait 100x100'lük girdi boyutu ile sınıflandırma sonucu..	24
Şekil 6-9 İki sınıflı veriseti ile 5-Katmanlı ESA kullanımı durumunda elde edilen sonuçlar.	26
Şekil 6-10 Görüntülerin boyut karşılaştırması.....	27
Şekil 6-11 300x300'lük girdi boyutu ile elde edilen eğitim sonucu.	27
Şekil 6-12 300x300'lük girdi boyutu ile elde edilmiş sınıflandırma başarıımı.....	28
Şekil 6-13 OneCycleLR algoritması 10-2 ile 10-3 aralığında eğitim sonuçları.....	30
Şekil 6-14 OneCycleLR algoritması 10-2 ile 10-3 aralığında sınıflandırma sonuçları.....	31
Şekil 6-15 ReduceLROnPlateau algoritması 10-2 ile 10-3 aralığında eğitim sonuçları.	32

Şekil 6-16 ReduceLROnPlateau algoritması 10-2 ile 10-3 aralığında sınıflandırma sonuçları.....	32
Şekil 6-17 5x5'lik Evrişim filtreleri kullanımı ile elde edilen eğitim başarımı.	34
Şekil 6-18 5x5'lik Evrişim filtreleri kullanımı ile elde edilen sınıflandırma başarımı.	34
Şekil 6-19 4 Evrişim Katmanına sahip ESA yapısı.	36
Şekil 6-20 6 katmanlı ESA yapısı.	36
Şekil 6-21 6 Katmanlı ESA Mimarisi kullanımı durumunda, eğitim başarımı.	37
Şekil 6-22 6 Katmanlı ESA yapısına ait test sonuçları.....	37
Şekil 6-23 İki sınıflı veri seti ile 6-Katmanlı ESA kullanılması durumunda elde edilen sonuçlar.....	38
Şekil 6-24 Resnet50 eğitim başarım sonucu.	41
Şekil 6-25 Resnet50 test başarım sonucu.	41
Şekil 6-26 İki sınıflı veri seti ile Resnet50 kullanılması durumunda elde edilen test sonuçları.....	42
Şekil 6-27 Klasik Makine Öğrenmesi Yöntemlerinin kullanımına yönelik yapı.	43
Şekil 6-28 Lineer DVM yöntemiye ait eğitim sonuçları.	45
Şekil 6-29 Lineer DVM yöntemiye ait test sonuçları.....	45
Şekil 6-30 İki sınıflı ver seti ile Lineer DVM yönteminin kullanılması ile elde edilen sonuç.	46

SİMGELER VE KISALTMALAR

DN	Doğru Negatif
DP	Doğru Pozitif
DT	Decision Trees (Karar Ağaçları)
DVM	Destek Vektör Makineleri
ESA	Evrişimsel Sinir Ağları
K-EYK	K En Yakın Komşu
NB	Naif Bayes
RF	Radyo Frekans
RKA	Radat Kesit Alanı
ROHT	Radat Otomatik Hedef Tanımlama
SGO	Sinyal Gürültü Oranı
YSA	Yapay Sinir Ağları
YN	Yanlış Negatif
YP	Yanlış Pozitif

1. GİRİŞ

Günümüzde drone teknolojileri konusunda yaşanan gelişmeler ile dronelar günlük hayatımızda büyük bir yer almaya başladı. Bu durum, Dronelerin hem sivil hemde askeri amaçlar için kullanımını büyük ölçüde yaygınlaştırdı. Dronelerin kolay erişilebilir olması ve 7'den 70'e herkes tarafından kolay kullanılabilir olması Drone kullanım oranını büyük ölçüde arttırmaktadır. Drone sistemlerinin pazar payının büyük olması, dronelerin maddi olarak herkes tarafından erişilebilir olması, parçalarına kolay erişim sağlanabilmesi ve evde kolayca imal edilebilmesi gibi durumlar drone sistemlerinin hem askeri amaçlar için hem de terör saldırıları gibi durumlar için kullanımını kolaylaştırmaktadır. Sivil kullanıma yönelik üretilmiş dronelerin silahlandırılması ile çeşitli savaşlarda, saldırılarda ve kaçakçılık gibi farklı illegal aktivitelerde kullanılması [1][2][3][4] bu sistemlerin tespitinin ne denli önemli olduğunu gözler önüne sermektedir. Drone ve kuşların sınıflandırılması ve ayırt edilmesinin önemi hem savaş alanında hem de kritik tesis ve altyapıların terörist saldırılardan korunmasında önemlidir. Örneğin, havaalanları, askeri üsler, askeri konvoylar, hükümet binaları, nükleer santraller, elektrik santralleri, barajlar vb.

Literatürdeki çalışmalar incelendiğinde, dronelerin tespitine yönelik çalışmalardaki artışın bu durumun önemindeki artış ile paralel olduğu görülmektedir. Geleneksel Radar Kesit Alanı (RKA) ve nesne hızı ile sınıflandırma yöntemlerinin dronelar için yetersiz kalması çalışmaların makine öğrenmesi yöntemleri gibi farklı tespit yöntemlerine yönelmiştir.

Dronelara ait RKA izlerinin görece diğer hedeflerden küçük olması, bu dronelerin radarların geleneksel sınıflandırma algoritmaları ile tespitini zorlaştırmaktadır. Ayrıca, dronelerin boyutlarının ve hızlarının havadaki farklı biyolojik hedeflere benzerlikleri nedeni ile ayrıştırılmasını güçleştirmektedir. Bu duruma verilebilecek en büyük örnek, dronelar ile kuşların RKA ve hız bakımından birbirlerine çok yakın çıkmalarıdır.

Bu çalışma, drone ve kuşların FMCW radardan elde edilmiş mikro-doppler izleri üzerinden ayırt edilmesine yönelik makine öğrenmesi yöntemleri kullanılarak gerçekleştirilmiştir. Bu çalışmada önerilen yöntemlerden, klasik makine öğrenmesi yöntemlerinin yanı sıra, uçtan-uca oluşturulmuş ESA mimarisi, önceden eğitilmiş Evrimsel Sinir Ağı (ESA) mimarileri kullanılmış olup yüksek başarımlar elde edilmiştir. Bu çalışmada, ESA mimarisi ile özneteliklerin çıkartılarak Destek Vektör Makinası ile sınıflandırılması sonucunda en yüksek doğruluk değeri %98.04 olarak elde edilmiştir.

1.1. Çalışmanın Amacı

Frekans Modülasyonlu Sürekli Dalga (Frequency Modulated Continuous Wave,FMCW) radardan elde edilmiş olan Eşevreli Dördün Evreli(In-Phase Quadrature, IQ) veriler ile sınıflandırma yapılması geçmişte olduğu gibi bugün de belirtilen probleme yönelik çözüm olabileceği değerlendirilmektedir. Kullanılan veri setinde yer alan IQ verilerin işlenerek ESA algoritmasına uygulanması ve bu algoritma sonucunda elde edilen sonuçlar ile Dronelerin yüksek başarımla kuşlardan ayrıştırılması ve drone türünün tespiti amaçlanmıştır.

1.2. Tezin Organizasyonu

77 GHz FMCW radardan elde edilmiş olan ham veriler üzerinden ön işlem faaliyeti gerçekleştirilip farklı tehditlere yönelik sınıflandırılmasını amaçlayan bu tez çalışması, aşağıdaki gibi yedi farklı bölümden oluşacak şekilde organize edilmiştir.

Çalışmanın birinci bölümünde tez çalışmasında amaçlanan doğrultuda gerçekleştirilmiş çalışmalardan bahsedilmiş ve genel tezin organizasyonu açıklanmıştır.

Tezin ikinci bölümünde, çalışmada kullanılmış veri setinde yer alan IQ verilerin avantaj/dezavantajlarını, dünya çapında artan Drone kullanım faaliyetlerinin ve makine öğrenmesi yöntemi ile drone tespitine yönelik avantaj/dezavantajların bahsedildiği bölümdür.

Çalışmanın üçüncü bölümünde, literatürde yer alan benzer çalışmalardan bahsedilmektedir.

Çalışmanın dördüncü bölümünde, çalışma boyunca kullanılacak olan veri setinin içeriği ile ilgili bilgi verilmektedir.

Çalışmanın beşinci bölümünde, çalışma kapsamında kullanılacak olan derin öğrenme ve makine öğrenmesi yöntemleri hakkında bilgi verilmektedir.

Çalışmanın altıncı bölümde, çalışma kapsamında gerçekleştirilmiş olan deneyler ve çalışmalar anlatılmaktadır.

Çalışmanın son bölümünde, elde edilen sonuçların açıklamaları ve öneriler yer almaktadır.

2. RADAR VERİLERİ VE DERİN ÖĞRENME

Günümüzde sayısal kartların ve işlemcilerin yaygınlaşması ile güncel üretilen/tasarlanan radarların çoğunluğu elde edilen Radyo Frekans(RF) sinyalleri temel bant işaretine indirerek IQ veri olarak işlemektedir. Bu yöntemin kullanılmasının farklı avantajları ve dezavantajları mevcuttur. Radarlarda Temel Bant işaretine indirilmesinin avantajları aşağıdaki şekilde sıralanabilir. [5][6][7][8]


- Geniş bantta elde edilmiş sinyallerin kolay işlenebilirliği
- Dijital sinyal işleme tekniklerinin kullanılması olanağı ile modern sinyal işleme yöntemlerinin kullanımı.
- Gürültü ve karmaşanın azaltılması
- Sinyallerin kolay bir şekilde modülasyonu ve demodülasyonunun yapılması.
- Kullanılan sayısal kartlar ve işlemciler ile, verilerin gerçek zamanlı olarak işlenebilmesi olanağı.

RF sinyallerin temel bant işaretine indirilerek kullanılmasının avantajları olduğu gibi bazı dezavantajlarında bulunmaktadır. Bu dezavantajları aşağıdaki gibi sıralayabiliriz. [5][6][7][8]

- Sayısal olarak kaydedilmiş verilerin boyutları. IQ verilerin boyutlarının yüksekliği nedeni ile depolama için yüksek veri hacmine sahip depolama donanımlarının gerekliliği
- IQ verilerin karmaşıklığı nedeni ile kullanılacak olan sinyal işleme algoritmalarının kompleksliği.
- IQ verilerin işlenmesindeki senkronizasyon gereksinimi.
- Dönüşümden kaynaklanabilecek hatalar ve hassasiyet etkileri.

Dünya üzerinde drone kullanımı her geçen gün artmaktadır. İnsansız hava platformlarının üretimine ve kullanımına yönelik ilk çalışma olarak kabul edilen 1918’de üretilmiş olan “Kattering Bug” insansız torpido kamikaze amaçlı hava uçağıdır [9]. Modern kullanımda ise öncü olarak kabul edilen ilk insansız platform 1951 yılında kullanılan [10]“Ryan Firebee” jet tahrikli insansız platformdur. Bu gelişmelerden sonra günümüzde insansız hava platformlarının kullanımı kolay erişilebilirlik gibi nedenlerle çok artmıştır.

Drone kullanımına yönelik ZION Market Research adlı sitenin araştırması ve ön görüşüne göre, Dünya çapında drone üretimine yönelik Pazar büyüklüğü aşağıdaki gibidir.[11]



Şekil 2-1 ZION Market Research firmasının, drone pazar büyüklüğü tahmini.[11]

Ayrıca, 24 Şubat 2022’de başlayan Rusya-Ukrayna savaşında, Ukrayna Ordusunun aylık olarak yaklaşık 10.000 drone kullandığı belirtilmektedir. [11]

Farklı alanlarda olduğu gibi Savunma sistemleri ile hedeflerin tespit ve sınıflandırmasında da Makine Öğrenmesi, yapay zeka kullanımının farklı faydaları vardır. Bu faydaları aşağıdaki gibi sıralayabiliriz.[12]

- Yüksek doğruluk ile nesnelerin tespit ve sınıflandırılması.
- Yapay zeka ve makine öğrenmesi yöntemleri kompleks öznitelikleri öğrenebilir. Bu neden ile manuel olarak öznitelik çıkartım ihtiyacı azalmaktadır.
- Yapay zeka yöntemleri ile veri iyileştirme yapılması kolaylaşır.
- Yapay zeka yöntemleri ile hedeflerin hareketlerine yönelik öngörü yeteneği artmaktadır.
- Davranışları öğrenerek normal ve anormal davranışları tespit edebilir ve bu

minvalde uyarı verebilir.

- Çoklu sensörlerden gelen büyük verilerin işlenmesini kolaylaştırır ve sensörlerin füzyonuna yönelik kolaylık sağlar.

3. LİTERATÜRDEKİ ÇALIŞMALAR

Literatürde Radar sinyalleri üzerinden drone tespiti için güncel durumlar göz önüne alındığında birçok araştırma ve çalışma mevcuttur. Bu çalışma kapsamında birçok kaynak taraması yapılmış. Çalışma süresince en çok yararlanılan ve benzer konulara sahip olan kaynaklar aşağıda detaylandırılmaktadır.

Bu çalışmalardan birisi, Alexander Karlsson, M. Jansson ve M. Hämäläinen'in gerçekleştirmiş olduğu 2022 yılında gerçekleştirilen, 77 GHz FMCW radar verileri üzerinden ön işleme faaliyetleri yapılarak ESA algoritması kullanımı ile Drone sınıflandırma üzerine yapılmış olan çalışmadır [13]. Bu çalışmada kullanılmış olan veri seti, IQ radar verileri, hedeflerin menzil bilgisini ve zaman bilgisini içermektedir. Çalışmada kullanılan veri setinde toplamda 75868 veri yer almaktadır. Bu veriler, 6 adet farklı drone sınıfına, 2 adet farklı insan faaliyetine (Yürüme ve koşma), 6 farklı kuş sınıfına ve bir korner reflektöre ait ölçümleri içermektedir. Bu çalışmada, ilk olarak elde edilen veriler ile yapılan ön işlemler sonrasında ESA ile sınıflandırma sağlanmıştır. Bu sınıflandırma sonucunda %90 başarımla elde edilmiştir. Bu başarımın artırılması amacı ile tespitlerin SGO'ları üzerinde iyileştirme yapılarak başarımın artırılması hedeflenmiştir. Ayrıca, bu çalışmadaki veri setinin yanı sıra sentetik veri üretilmiş, bu sentetik veriler de çalışmada başarımın iyileştirilmesi için dahil edilmiştir. Bu çalışmada kullanılmış olan veri seti paylaşımına açıktır ve açık kaynak üzerinden erişilebilmektedir.[13]

Bir diğer çalışma ise, D. White, M. Jahangir, J. P. Wayman, S. J. Reynolds, J. P. Sadler ve M. Antoniou'un 2023 yılında yayınlamış olduğu çalışmadır [14]. Bu makalede, L Bant radardan elde edilmiş iki farklı veri seti bulunmaktadır. İlk veri seti, tek hedefin yer aldığı verileri içermektedir. Bu veri seti içerisinde 35 kuş ve 10 drone sınıfına ait ölçümler yer almaktadır. Bu veri seti ile ESA üzerinden çalışma yapılmış ve tek hedefli veriler için başarımlar %82 doğruluğunda sağlanmıştır. Ayrıca, ikinci bir veri seti ile çalışma tekrarlanmıştır, bu veri setinde 64 kuş ve 95 drone bulunmaktadır. Bu karmaşık veri setinin kullanılması ile %89-90 aralığında bir başarımla elde edilebilmiştir. [14]

J. Wang, Y. Li, Y. Lin, ve W. Shen'in gerçekleştirdiği çalışmada[15], radar otomatik hedef tanıma (4ROHT) teknolojisinin gelişimini ve derin öğrenme algoritmalarının bu alandaki uygulamalarını detaylı bir şekilde incelemektedir. ROHT, radar sinyal işleme ve yapay zeka yöntemlerini kullanarak çeşitli hedeflerin tanınmasını sağlar. Özellikle 2010-2022 yılları arasında yayımlanan çalışmalar ele alınmış ve derin öğrenme yöntemlerinin ROHT ile performansları vurgulanmıştır. Örneğin, uzay hedeflerinin tanınmasında AlexNet ve SqueezeNet modelleri ile %97.5 doğruluk elde edilmiştir. Benzer şekilde, Uzun-Kısa Vadeli Hafıza tabanlı bir model, balistik füze ve sahte hedeflerin tanınmasında %99 doğruluğa ulaşmıştır. Hava hedeflerinin tanınmasında, ESA tabanlı bir model ile dronlar için %96.86 doğruluk sağlanmıştır [15]. Bu sonuçlar ile, derin öğrenme algoritmalarının ROHT sistemlerinde yüksek performans sağladığını ve bu alandaki gelecekteki araştırmalar için önemli bir temel oluşturduğunu göstermektedir. ROHT sistemlerinin başarısını artırmak için, derin öğrenme yöntemlerinin daha fazla entegrasyonu ve optimizasyonu üzerinde durulması gerektiği belirtilmiştir.[15]

Harish Chandra Kumawat, Mainak Chakraborty, A. Arockia Bazil Raj ve Sunita Vikrant Dhavale'in 2022 yılında, yayınladığı çalışmada, düşük radar kesitine (RKA) sahip küçük hava hedeflerinin(Örneğin drone), mikro-Doppler imzalarını kullanarak sınıflandırılması üzerine odaklanmaktadır[16]. Makale kapsamında DIAT-μSAT adı verilen, 4849 mikro-Doppler imza görüntüsünden oluşan bir veri seti geliştirilmiştir.[16] Bu veri seti, iki bıçaklı rotor, üç kısa bıçaklı rotor, üç uzun bıçaklı rotor, dört pervaneli drone (quadcopter), biyonomik kuş ve iki bıçaklı rotor ile biyonomik kuşun birlikte çalıştığı durumlar gibi altı farklı sınıfı içermektedir[16]. Veri seti, çalışma kapsamında geliştirilmiş bir X-band sürekli dalga (CW) radar kullanılarak toplanmıştır ve bu radar ile küçük hava hedeflerinin mikro-Doppler imzaları kaydedilerek veri seti oluşturulmuştur[16]. Makalede, VGG16 ve VGG19 modelleri kullanılmış ve sırasıyla %95 ve %97 sınıflandırma doğruluğu elde edilmiştir[16]. Bu çalışma, küçük hava hedeflerinin tespitinde ve sınıflandırılmasında radar mikro-Doppler imzalarının kullanımını detaylandırmakta ve DIAT-μSAT veri setinin radar tabanlı hedef tanıma araştırmaları için önemli bir kaynak olduğunu vurgulamaktadır[16].

R. M. Narayanan, B. Tsang, ve R. Bharadwaj'in 2023 yılında yayınladıkları kuşlar ve küçük dronların mikro-doppler izlerine bakılarak ayırt edilmesine yönelik bir çalışmadır[17]. Bu çalışma için geliştirilmiş 10 GHz(X-bant) radar ile elde edilen ölçümler ile veri seti oluşturulmuştur[17]. Bu veri seti, kuş ve drone mikro-doppler spektrumlarından oluşan 700'den fazla veri bulunmaktadır[17]. Bu yayında, Destek vektör makineleri

kullanılarak yapılan sınıflandırmada, dron büyüklüğüne göre yaklaşık %90 doğruluk, kuş ve drone ayrımı için %96 doğruluk ve beş farklı sınıfta bireysel dron ve kuş ayrımı için yaklaşık %85 doğruluk elde edilmiştir [17].

4. KULLANILAN VERİ SETİ

Bu tez çalışmasında, 77 GHz FMCW radarda drone, insan hareketleri ve reflektöre için elde edilmiş radar verileri kullanılmaktadır. Bu çalışmada, İsveç KTH Kraliyet Teknoloji Enstitüsünün çevrimiçi erişime açık olan veri kullanılmıştır.[13] Bu veri setinde yer alan veriler, SAAB SIRS 1600 FMCW radarı kullanılarak toplanmıştır. Bu günlerde, bu denli yüksek frekansa sahip radarlar genellikle araçlar için sensör olarak kullanılmaktadır. Ayrıca, bu denli yüksek frekansların kullanılması mikro-doppler etkisinin daha iyi gözlemlenmesine yardımcı olmaktadır. Bu radara ait bilgiler Tablo 4-1 ile verilmektedir.

Tablo 4-1 Radar Parametreleri[13]

Radar Tipi	SAAB SIRS 1600, FMCW
Merkez Frekansı	77 GHz
Bant Genişliği	160 MHz
Menzil Çözünürlüğü	1 m
Darbe Tekrarlama Frekansı(PRF)	17 kHz
Azimut Bant Genişliği	1°
Tarama Hızı	10 Hz, Mekanik
Görüş Alanı	±9°
Çıkış Gücü(EIRP)	10 mW

Veri setinin analizinde, MAT-Dosyası olarak MATLAB yazılımı R2022b sürümü kullanılmıştır. Veri setinde verilen 130 satırın her biri bir ölçümün kaydedilmiş halidir. Veri setinin içeriği ağaç diyagramı ile Şekil 4-2 ile gösterilmektedir. Veri setinde toplamda 75868 ölçüm yer almaktadır. Bu ölçümlerin dağılımı Tablo 4-3 ile gösterilmektedir. Veri setinde belirtilmiş olan 6 sütunun birinci sütununda verilerin sınıflarına ait etiketler verilmektedir. Bu etiketler Tablo 4-2 ile gösterildiği gibidir.

Tablo 4-2 Veri setinde yer alan sınıflar


Sınıf	Açıklama
‘D1’	Drone, DJI matrice 200 v
‘D2’	Drone, DJI Mavic 2 Pro
‘D3’	Drone, DJI Phantom 3
‘D4’	Drone, Custom built FPV drone
‘D5’	Drone, Custom built with a Tarot 680 Pro frame
‘D6’	Drone, Syma X23W
‘human_walk’	Farklı insan yürümelerine ait ölçümler.
‘Human_run’	Farklı insan koşmalarına ait ölçümler.
‘seagull’	Uçan martı
‘pigeon’	Uçan güvercin
‘raven’	Uçan kuzgun
‘black-headed gull’	Uçan karabaş martı
‘seagull and black-headed gull’	Aynı anda uçan karabaş martı ve martı
‘heron’	Uçan balıkçıl
‘CR’	Üçgen reflektör, 77 GHz’de 100m ² RKA

Tablo 4-3 Veri seti içerisinde yer alan sınıfların dağılımları


Sınıf	Veri sayısı
Drone, DJI matrice 200 v	6921
Drone, DJI Mavic 2 Pro	9555
Drone, DJI Phantom 3	10212
Drone, Custom built FPV drone	8735
Drone, Custom built with a Tarot 680 Pro frame	12093
Drone, Syma X23W	12093
İnsan yürüme ve koşma	6028
Uçan kuşlar, kanat çırpması olan ve olmayan	7792
Üçgen Reflektör	3280

Veri seti içerisindeki 2.sütunda 5 adet tarama segmentine ait IQ verileri birleştirilmiş olarak sunulmaktadır. Veri setinin toplandığı radarın mekanik tarama kabiliyeti bulunmaktadır. Bu sebeple, her ölçüm 5 adet mekanik tarama segmentini içermektedir. Her tarama segmenti 1x256'lık bir vektör ile ifade edilmektedir. Her ölçüm için 5 adet tarama segmentinin birleştirilmiş hali 1x1280'lik bir veri içermektedir. Veri seti içerisindeki üçüncü sütun, hedefin tespit edildiği mesafeyi belirtmektedir. Veri seti içerisindeki dördüncü sütun, hedefin tarama zamanını belirtmektedir. Her tarama arasında 100ms bulunmaktadır. Veri seti içerisindeki beşinci sütun ise, verinin test, eğitim ve doğrulama için mi kullanılacağını belirtmektedir. Veri seti içerisindeki 6.sütunda ise görüş alanı dışında kalan ya da kaçırılmış olan taramaların belirtildiği kısımdır. Bu kısımda yer alan değer 1 ise bu taramanın görüş alanı dışında ya da kaçırılmış bir tarama olduğunu belirtmektedir. Bu çalışma kapsamında birinci, ikinci ve beşinci sütunlar kullanılarak analizler gerçekleştirilmiştir.

İkinci sütunda yer alan veriler incelendiğinde, beş mekanik tarama segmentine ait verilerin birleştirildiği görülmektedir. Bu tarama segmentleri için ayırma işlemi yapılmadan IQ verilere ait “Drone 1” sınıfı ile “Kuş” sınıfına ait bir örnek gösterimi Şekil 4-1 a. ve Şekil 4-1 b. ile gösterilmektedir.



Şekil 4-1 a. "Drone 1" sınıfına ait IQ veri. b. "Kuş" sınıfına ait bir IQ veri.



Şekil 4-2 Veri seti ağaç diyagramı.

Veri setinde yer alan toplam veri miktarı 75.868 olduğu için, veri sayısını arttırmaya yönelik bir çalışma yapılmamıştır. Verilerin 57.868 tanesi eğitim için, 9.000 tanesi doğrulama için ve 9.000 tanesi test için olacak şekilde ayrılmış ve kullanılmıştır. Bütün veriler sınıf etiketleri dikkate alınarak kullanılmıştır.

Ayrıca, aynı veri seti içerisinde yer alan kuş ve drone sınıfları birer sınıf haline getirerek iki sınıflı veri seti oluşturulmuştur. Bu veri seti içerisinde toplamda 66.560 ölçüm verisi bulunmaktadır. Bu verilerin, 52.560 adedi eğitim için, 7.000 adet veri test için ve 7.000 veri doğrulama için kullanılmıştır. Bütün veriler ikili sınıf etiketi dikkate alınarak kullanılmıştır.

5. KULLANILAN SINIFLANDIRMA ALGORİTMALARI


Sınıflandırma algoritmaları makine öğrenmesi altında farklı türlere göre incelenebilir.



Şekil 5-1 Yapay zeka algoritmalarının alt dalları

5.1 Makine Öğrenmesi

Makine öğrenmesi, insanların öğrenme yönteminin bilgisayarlara uyarlanma fikri ile ortaya çıkmış çeşitli algoritmalara ve tekniklerin bilim ve teknoloji ile birlikte kullanıldığı bir alandır. Makine öğrenmesi sürecinde, üç farklı öğrenme türü bulunmaktadır. Bu türler Şekil 5-2 ile gösterildiği gibidir.[18][19]



Şekil 5-2 Makine Öğrenmesi Öğrenme Türleri[18]

5.1.1 Denetimli Makine Öğrenmesi

Denetimli Makine Öğrenmesi, etiketli veriler ile eğitilen bir modelin giriş ve çıkış arasındaki ilişkileri öğrenerek dışardan gelebilecek yeni verilere ait tahminlerde bulunduğu bir öğrenme yöntemidir. Bu yöntemin genel uygulama alanlarına sınıflandırma örneği verilebilir. Bu öğrenme yöntemi için verilebilecek örnek algoritmalar aşağıdaki gibidir [18][19]:

- Doğrusal Regresyon
- Lojistik Regresyon
- Karar Ağaçları
- K-NN(K-en yakın komşu)

5.1.2 Denetimsiz Makine Öğrenmesi

Denetimsiz Makine Öğrenmesi, etiketli verilerin mevcut olmadığı durumlarda modelin veri içerisinde yer alan örüntü, desen ve yapıları keşfetmesi ile uygulanır. Bu uygulama sonrası dışardan gelebilecek yeni veriler ile tahmin yürütülebilir. Bu yöntemin genel kullanım alanlarına veri sıkıştırma ve anomali tespiti örnek verilebilir. Bu yöntemle verilebilecek örnek algoritmalar [18][19]:

- Kümeleme
- Boyut indirgeme

5.1.3 Pekiştirmeli Makine Öğrenmesi

Pekiştirmeli Makine Öğrenmesi, istenilen bir hedef doğrultusunda oluşturulmuş modelin belirlenmiş bir hedefe yönelik eylemlerine ödül ve ceza yöntemi uygulanarak en yüksek ödülün elde edilmesine yönelik en iyi yolu arayan bir model oluşturmaktır. Bu uygulamanın

kullanım alanlarına örnek olarak satranç oynama, otonom araçlar ve robotik alanı verilebilir. Bu yöntemle verilebilecek örnek algoritmalar [18][19]:

- Q-Öğrenme
- SARSA

5.2 Derin Öğrenme Algoritmaları

Derin Öğrenme, Makine Öğrenmesinin bir alt dalıdır. Derin Öğrenme, denetimli makine öğrenmesi problemleri için güçlü bir çözüm olanağı sağlamaktadır. Derin Öğrenme algoritmalarında özellikle yapay sinir ağlarının kullanılması ve bu yapay sinir ağlarının daha karmaşık ve derin versiyonlarının kullanılması ile verilerden yüksek seviyelerde nitelik çıkartımı yapılabilmektedir. Ayrıca, bu yöntem işlem yükünü arttırmasına rağmen bazı ihtiyaca yönelik durumlarda daha yüksek başarımlar elde edilebilmesine olanak sağlamaktadır.[20]

Bu tez çalışması kapsamında, Derin Öğrenme Algoritması olan Evrişimsel Sinir Ağları algoritması kullanılmıştır. Bu sebep ile Derin Öğrenme Algoritmalarında sadece kullanılmış olan Evrişimsel Sinir Ağları anlatılmıştır.

5.3 Evrişimsel Sinir Ağları

Evrimsel Sinir ağları, görüntü gibi bir, iki veya daha fazla boyutlu verilerin işlenmesine yönelik geliştirilmiş olan bir Yapay Sinir Ağı yöntemidir. Bu yöntemi diğer yöntemlerden farklı kılan durum, kullanılan sinir ağının içinde matematiksel işlem olan Evrişim işleminin yer almasıdır. ESA, kullanımı için sinir ağı katmanlarının herhangi birinde Evrişim işleminin yer alması, bu ağın ESA olarak adlandırılması için yeterlidir. [20]

Matematiksel evrişim operatörü olarak adlandırılan işlem, iki fonksiyonun bir araya getirilerek üçüncü bir fonksiyon haline getirilmesi olarak açıklanabilir. Örneğin, $x(t)$ olarak zaman ekseninde yer alan bir fonksiyonumuz olsun. Bu fonksiyonu, $w(t)$ olan başka bir ağırlık fonksiyonu ile evrişiminden oluşan yeni fonksiyonumuzu gözlemlemek için (Denklem 5.1)'deki işlemi uygulayabiliriz.[20]

$$s(t) = \int x(a)w(t - a)da \quad \text{Denklem 5.1}$$


Bu operasyona evrişim işlemi denmektedir. Bu işlem, tipik olarak yıldız(*) işareti ile gösterilmektedir.

$$s(t) = (x * w)(t)$$

Denklem 5.2

Evrişimsel Sinir Ağı terminolojisinde, Denklem 5.1 ve Denklem 5.2’de belirtilmiş olan $x(t)$ fonksiyonu girdi fonksiyonu olarak adlandırılır. Diğer fonksiyon olan $w(t)$ fonksiyonu ise kernel fonksiyonu olarak adlandırılmaktadır. $S(t)$ fonksiyonu ise genellikle çıktı fonksiyonu olarak adlandırılmaktadır.[20]


ESA yapıları genellikle, “evrişim”, “havulama” ve “tam bağlı” olmak üzere üç ana başlığa sahiptir. Evrişim işleminde, Denklem 5.1 ve Denklem 5.2’de belirtilen yöntemler [21]kullanılarak girdi olarak verilmiş bir görüntü kernel fonksiyonu uygulanarak farklı öznitelik çıkarımları yapılır. Bu öznitelik çıkarımlarına yönelik Şekil 5-3 ile gösterilmiş olan örnek verilebilir. Evrişim işleminde uygulanan filtre sayısı kadar farklı öznitelik oluşturulmaktadır. Bu filtre sayısı kullanım ihtiyacına ve ağ yapısına göre değişmektedir. [21]



Şekil 5-3 Evrişim, öznitelik çıkartımı.[21]

Havuzlama katmanının kullanılması girdi boyutunun azaltılarak hesaplama yükünü hafifletmeye ve bu neden ile daha verimli bir model oluşturmaya katkı sağlar. Ayrıca, girdi boyutunun azaltılması, aşırı öğrenme gibi istenmeyen durumlara yönelik riski azaltmaktadır [22]. Bu yöntemin kullanılmasının bir diğer amacı, en belirgin özniteliklerin korunarak daha az önemsiz olarak nitelendirilebilecek olan detayların ortadan kaldırılmasına olanak sağlar. Bir diğer avantaj ise, girdide yer alabilecek küçük değişikliklerin veya kaymaların tolere edilebilmesine yol açmaktadır.

Havuzlama işlemi, hedeflenen bir piksel konumunda yer alan komşu piksel hücrelerini bir araya getirerek tek bir değer haline getirir. Bu sayede resmin piksel boyutunu küçülterek yukarıda belirtilmiş avantajların kullanılmasına olanak sağlar. Örneğin, Şekil 5-4 ile iki farklı havuzlama yöntemine ait örnek bir gösterim yer almaktadır.[21]




Şekil 5-4 İki farklı havuzlama yöntemi.[21]

5.4 Klasik Makine Öğrenmesi Yöntemleri

Bu tez çalışması kapsamında, klasik makine öğrenmesi yöntemlerinden karar ağaçları, K-en yakın komşu, Destek Vektör Makineleri(DVM) yöntemleri kullanılmıştır.

Karar ağacı, verilerin belirli özelliklerine göre ayrıştırılarak sınıflandırıldığı bir makine öğrenimi algoritmasıdır. Ağaç yapısında her düğüm bir özellik, dallar bu özelliklerin olası değerlerini, yaprak düğümleri ise sınıflandırma sonucunu temsil eder. Bu yapı, hem kategorik hem de sayısal verilerle çalışabilir ve veri üzerinde ayrıştırmalar yaparak karar verir. Karar ağaçları, özellikle şeffaflığı ve kolay anlaşılabilirliği nedeniyle tercih edilen bir yöntemdir [5].


Karar ağacı yapıları, sınıflandırma işlemlerinin verilerin belirli özelliklerine göre yapıldığı bir makine öğrenimi algoritmasıdır. Ağaç yapılarında her düğüm bir özelliği, dallar ise bu özelliklerin olası değerlerini ve yaprak düğümleri ise sınıflandırma sonuçlarını belirtmektedir. Örnek bir karar ağacı yapısı Şekil 5-5 ile gösterilmektedir.[23]



Şekil 5-5 Karar Ağacı yapısı.

K-En Yakın Komşu algoritması, sınıflandırma ve regresyon problemlerinde kullanılan, denetimli bir makine öğrenmesi yöntemidir. Bu yöntem verilerin uzaklık hesaplamasına dayanan bir yaklaşım içerir. K değişkeni en yakın komşu sayısını ifade etmektedir. Bu değişken ihtiyaç doğrultusunda 1'den büyük herhangi bir değer alabilmektedir.[24]

Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon analizlerinde kullanılan güçlü bir denetimli öğrenme algoritmasıdır. DVM, verileri yüksek boyutlu bir uzaya dönüştürerek bu uzayda en iyi ayıran hiper düzlemi bulur. Hedef, farklı sınıflara ait veri noktalarını en geniş marjinal mesafeyle ayırmaktır. DVM, doğrusal olmayan problemler için çekirdek fonksiyonları kullanarak daha karmaşık sınıflandırma görevlerini de yerine getirebilir.[25]



Şekil 5-6 DVM yapısı.[26]

5.5 Başarım Kriterleri

Bu çalışma kapsamında, başarımların ölçülebilmesi amacı ile dört farklı başarım ölçütü kullanılmıştır. Bu ölçütler, doğruluk, kesinlik, duyarlılık ve F1-Score yöntemleridir.

Doğruluk kriteri, doğru tahmin edilen sonuçlar ile toplam örnek sayılarının oranıdır. Bu yöntem için Denklem 5.3 ile kullanılmıştır.

$$\text{Doğruluk} = \frac{\text{Doğru Ölçüm Sayısı}}{\text{Toplam Ölçüm Sayısı}} \quad \text{Denklem 5.3}$$

Kesinlik kriteri, doğru pozitif tahminlerin, doğruluğunun ölçülmesi amacı ile kullanılmaktadır.[27] Denklem 5.4’de gösterildiği şekilde kullanılmıştır.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif (DP)}}{\text{Doğru Pozitif (DP)} + \text{Yanlış Pozitif (YP)}} \quad \text{Denklem 5.4}$$

Duyarlılık Kriteri, Gerçek Pozitif olarak elde edilen sonuçların ne kadar doğru bir şekilde tahmin edildiğine yönelik bir ölçüm kriteri olarak Denklem 5.5’de gösterildiği gibi kullanılmıştır.[28]

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif (DP)}}{\text{Doğru Pozitif (DP)} + \text{Yanlış Negatif (YN)}} \quad \text{Denklem 5.5}$$

F1-Score yöntemi, Kesinlik ve Duyarlılığın harmonik ortalaması ile başarım kriterini hesaplamaya yöneliktir. Bu yöntem için Denklem 5.6’da belirtilen formül kullanılmıştır.[32]

$$F1 - \text{Score} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad \text{Denklem 5.6}$$

6. UYGULANAN YÖNTEMLER

Bu tez çalışmasında, radar verilerinin sınıflandırılması için gerçekleştirilen çalışmalar aşağıdaki gibidir;

- Girdi boyutunun farklı değerler uygulanarak değiştirilmesi.
- Adaptif Öğrenme Algoritmalarının kullanılması
- ESA Filtre boyutlarının etkisinin gözlemlenmesi
- ESA Katman sayısının 4 katman ve 6 katman olacak şekilde düzenlenerek etkisinin gözlemlenmesi.
- Önceden eğitilmiş sinir ağlarının etkilerinin gözlemlenmesi
- Klasik Makine Öğrenmesi yöntemlerinin başarımlarının gözlemlenmesi

Bu çalışma kapsamında, kullanılan veriler için uygulanan ön işlem faaliyetleri, kullanılan ESA yapıları ve gerçekleştirilen çalışmalar bu başlık altında detaylandırılmaktadır.

6.1 Radar verisinin Ön İşlemesi


Veri seti bölümünde belirtildiği üzere IQ veriler beş adet tarama segmentine ait ölçümleri içermektedir. Zaman ekseninde bulunan bu IQ veriler, öncelikle Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform, STFT) ile frekans eksenine geçirilmiştir. Bu dönüşüm için MATLAB yazılımının sağladığı STFT dönüşümü kullanılmıştır. Kısa Zamanlı Fourier Dönüşümü için kullanılmış olan denklem (1) ve STFT spektrogram dönüşümü için kullanılmış olan denklem (2) ile gösterilmiştir.

$$STFT(t, f) = \int_{-\infty}^{+\infty} x(t)w(t - \tau)e^{-j\omega\tau}d\tau \quad (1)$$


$$SPECTOGRAM\{t, f\} = |STFT(t, f)|^2 \quad (2)$$

Veri setinin toplandığı radara ait Darbe Tekrarlama Süresi değeri 17 kHz olduğu için Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) için kullanılacak olan örnekleme frekans değeri de 17 kHz olarak seçilmiştir. IQ veride yer alan her tarama segmenti için 256 örnek bulunmaktadır. Bu sebep ile, FFT örnekleme noktası sayısı 256 olarak seçilmiştir. STFT fonksiyonu için pencere olarak Hamming penceresi seçilmiştir. Bu pencerenin uzunluğu 256 olarak alınmış olup, Örtüşme (Overlap) uzunluğu 120 olarak belirlenmiştir. Belirtilen parametrelere göre verilerin STFT'leri alındıktan sonra Spektrogramları çizdirilmiş ve bu Spektrogramlar kaydedilmiştir. Daha önce de belirtildiği üzere bu spektrogramlar 5 adet tarama segmentinin birleştirilmiş halidir. 5 tarama segmentine ait bir örnek spektrogram görüntüleri Şekil 6-2 ile gösterilmektedir.

Veri seti başlığında da belirtildiği üzere bir ölçüm 1x256'lık beş adet tarama segmentini içermektedir. Bir ölçümde yer alan 5 tarama segmentinin gösterimi Şekil 6-1'deki gibidir. Her ölçüme ait spektrogramlarda en yüksek sinyal gücüne ait olan tarama segmenti genellikle 3.tarama segmenti olduğu gözlemlenmiştir. Ancak, farklı segmentlerde en yüksek güç bulunması durumu ihtimaline karşılık her segmentin sinyal gücü hesaplanarak karşılaştırılmış ve en yüksek güce sahip sinyalin bulunduğu tarama segmenti verisinin spektrogram görüntüsü kaydedilerek ESA algoritmasına uygulanmıştır. Bu kısım 5 segmentin birleştirilmiş hali ile doğruluğun kıyaslanması için kullanılacaktır.



Şekil 6-1 “Drone 1” sınıfına ait, bir ölçümde yer alan beş tarama segmentine ait spektrogram gösterimi.




Şekil 6-2 Bütün sınıflara ait örnek 5 tarama segmentli bir spektrogram görüntüsü.

6.2 Algoritmada Kullanım için Veri setinin Tekrar Organize Edilmesi

ESA kullanımı için, spektogramların görüntü olarak kaydedilmesi gerekmektedir. ESA için kullanılabilecek formatlar, “.jpg, .png vb.”dir. Bu çalışmada spektogramlar “.jpg” formatında kaydedilmiştir. Bu kayıt sırasında veri seti içerisinde yer alan sınıf etiketleri dikkate alınarak isimlendirilmiştir.

Bu çalışmada, bazı sınıflar bir araya getirilerek tek bir sınıf olarak birleştirilmiştir. Birleştirilen sınıflar Şekil 6-3 ile gösterildiği gibidir. Şekil 6-3 ile gösterildiği üzere bütün drone ve Reflektörler kendi sınıf etiketleri ile kullanılmıştır. “Human_walk” ve “Human_run” sınıfları, kuş sınıfları gibi birleştirilerek birer sınıf haline getirilmiştir. Toplamda 9 sınıf elde edilmiştir.



Şekil 6-3 Çalışma kapsamında ölçümlere ait sınıfların tekrar organize edilmesi.

6.3 Kullanılan ESA yapısı


Veri setinin eğitimi ve sınıflandırılması için çalışmalar MATLAB yazılımı üzerinden yapılmıştır. Bu yazılım ile, ESA algoritması kullanılarak sınıflandırma hedeflendirilmiştir.

Bu çalışma boyunca kullanılan ESA yapısı aşağıda belirtildiği gibidir.

İlk olarak, spektrogram çıkartımı ile elde edilmiş olan görüntü ESA algoritmasına besleneceği bir “giriş katmanı” bulunmaktadır.

İkinci katman olarak evrişim ve havuzlama katmanlarının bulunduğu yapı bulunmaktadır.


Bu yapının her katmanının özelliği Şekil 6-4 ile gösterildiği gibidir.



Şekil 6-4 Kullanılan temel 5 Katmanlı ESA yapısı.


6.4 Sınıflandırma

Sınıflandırma aşaması ön işleme metotları uygulandıktan sonra uygulanmış olup sonuçlar paylaşılmıştır. ESA algoritmasının başarımının denenmesi amacı ile ESA yapısında belirtilmiş olan giriş katmanına beslenen Girdi Boyut değeri 100x100 olarak alınmıştır. Spektrogram görüntülerin orijinal piksel boyutu 656x875x3 şeklinde RGB görüntülerdir. ESA algoritmasını MATLAB yazılımı üzerinde hızlı bir şekilde denemek amacı ile Spektrogram görüntülerinin boyutu, 100x100'lük olacak şekilde 5 tarama segmenti için denenmiştir. Elde edilen sonuç Şekil 6-5 ile gösterildiği gibi eğitim başarımı %97.99 olarak çıkmıştır.



Şekil 6-5 100x100 Girdi Boyutu ile elde edilen eğitim sonucu


Eğitim sonucunda sınıflandırma sonucu için başarıım %97.72 olarak Şekil 6-6 ile gösterildiği gibi elde edilmiştir.



Şekil 6-6 100x100'lük girdi boyutu ile elde edilen sınıflandırma sonucu.

ESA algoritmasının başarılı bir şekilde çalıştığı görüldükten sonra, ilk olarak tek tarama segmenti ve beş tarama segmentinin birleştirildiğinde elde edilen başarımlar kıyaslanmak istenmiştir.

Tek tarama segmentini içeren spektrogram görüntüleri kaydedilerek ESA algoritmasına beslenmiş ve eğitim başarımı %91.88 olarak Şekil 6-7 ile gösterildiği gibi elde edilmiştir.



Şekil 6-7 Tek tarama segmentine ait 100x100'lük girdi boyutu ile eğitim sonucu.

Eğitim sonrası sınıflandırma performansları da kıyaslanmak için gözlemlenmiştir. Tek tarama segmentine ait spektrogramların sınıflandırma başarımları %91.69 olarak Şekil 6-8 ile gösterildiği gibi elde edilmiştir.

1	532	11	112	3	20	3		6	12
2	7	971	17		5				
3	8	14	105	8	20	1		15	1
4	1	3	37	837	55	60		7	
5	1	1	49	31	904	9		5	
6	1	5	20	58	10	908			
7			1	1	2		907	20	9
8	6	1	29	1	7		51	800	6
9								2	999
	1	2	3	4	5	6	7	8	9

Şekil 6-8 Tek tarama segmentine ait 100x100'lük girdi boyutu ile sınıflandırma sonucu.

Sonuçlardan da görüldüğü üzere 5 tarama segmentinin birleştirilerek sınıflandırma için kullanılması başarımları olarak daha etkilidir. Bu durum, aynı hedefin farklı açılardan

gözlemlenmesi spektrogram görüntüsünde ayrıştırıla bilirliliğini arttırdığı için mantıklı bir sonuç olduğu değerlendirilmektedir. Bu iki sonuç karşılaştırmasından sonra, çalışma beş tarama segmentinin birleştirilmiş olduğu spektrogram görüntüleri kullanılarak sürdürülmüştür. Elde edilen sonuçlara yönelik başarımların değerlerinin yer aldığı sonuçlar Tablo 6-1 ile gösterilmiştir.

Tablo 6-1 Tek tarama segmenti ve Beş Tarama segmentine yönelik başarımlar.


Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Keskinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Beş Tarama Segmenti(100x100 piksel)	Radar verilerine ait beş tarama segmentinin tek bir spektrogram haline getirilmesi	97.99	97.72	97.74	97.72	97.73	0.9744	885dk 50 sn
Tek Tarama Segmenti	Radar verilerindeki en yüksek yansıma sahip segmentin alınarak algoritmaya beslenmesi	91.88	91.69	92.07	91.69	91.72	0.9065	854dk 24sn

Beş tarama segmentine ait spektrogram görüntülerinin kullanılması ile elde edilmiş olan başarımların değerinin %97.72 çıkmasından sonra bu başarımların artırılmasına yönelik çalışmalar gerçekleştirilmiştir. Gerçekleştirilen çalışmalar aşağıdaki gibidir;

- Girdi boyutunun farklı değerler uygulanarak değiştirilmesi.
- Adaptif Öğrenme Algoritmalarının kullanılması
- ESA Filtre boyutlarının etkisinin gözlemlenmesi
- ESA Katman sayısının 4 katman ve 6 katman olacak şekilde düzenlenerek etkisinin gözlemlenmesi.
- Önceden eğitilmiş sinir ağlarının etkilerinin gözlemlenmesi
- Klasik Makine Öğrenmesi yöntemlerinin başarımlarının gözlemlenmesi

Ayrıca, 9 sınıflı veri seti ile gerçekleştirilen deneme sonrasında, iki sınıflı veri seti ile beş segmentli görüntüler üzerinden deneme gerçekleştirilmiştir. Deneme sonucunda, elde edilen eğitim başarımları %99.19'dur. Bu deneme sonrasında elde edilen test başarımları ise

%99.27 olarak elde edilmiştir. Elde edilen sonuçlar aşağıdaki Tablo 6-2 ile gösterildiği gibidir. Elde edilen sonuçlar Şekil 6-9 ile gösterildiği gibidir.



Şekil 6-9 İki sınıflı veriseti ile 5-Katmanlı ESA kullanımı durumunda elde edilen sonuçlar.


Tablo 6-2 İki sınıflı verilere ait eğitim ve test başarımları.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
İkili sınıf, Beş Tarama Segmenti(100x100 piksel)	İki sınıflı verilerin beş tarama segmentinin tek bir spektrogram haline getirilmesi	99.19	99.27	98.38	98.66	98.52	0.970	711dk 56sn

6.4.1 Girdi Boyutlarına Göre Gerçekleştirilen Çalışmalar


Daha önce de belirtildiği üzere spektrogram görüntülerinin orijinal piksel boyutu 656x875x3 şeklinde RGB görüntülerdir. Bu görüntüleri tekrar boyutlandırılması sağlanarak başarımlar artırma hedeflenmiştir. Bu boyutlar, 100x100, 300x300, 500x500 ve 600x600 olacak

şekilde uygulanarak aşağıda sonuçlar paylaşılmıştır. Görüntülerin boyutlara göre örnek değişimleri Şekil 6-10 ile gösterilmiştir.



Şekil 6-10 Görüntülerin boyut karşılaştırması.

Girdi olarak kullanılan spektrogramlar ile en yüksek başarımla, 100x100'lük piksel boyutundan sonra 300x300'lük piksel boyutunun kullanılması ile elde edilmiştir. 300x300'lük olacak şekilde güncellenmiş ve ESA algoritmasına beslenmiştir. Bu besleme sonucunda eğitim başarımları %96.84 olarak Şekil 6-11 ile gösterildiği gibi elde edilmiştir.



Şekil 6-11 300x300'lük girdi boyutu ile elde edilen eğitim sonucu.

Eğitim aşaması tamamlandıktan sonra sınıflandırma başarımı gözlemlenmek istemiştir. Sınıflandırma başarımı %96.81 olarak elde edilmiş olup. Başarım için gözlemlenen sonuçlar Şekil 6-12 ile gösterildiği gibidir.

1	945	18	10		24		1		2
2	2	994	1		3				
3	3	2	943	5	29	4	1	13	
4		3	4	944	12	33		4	
5		2	15	2	975	5		1	
6			5	8		986		1	
7					1		997	1	1
8	3		21	1	7	4	20	943	1
9	5							1	994
	1	2	3	4	5	6	7	8	9

Predicted Class

Şekil 6-12 300x300'lük girdi boyutu ile elde edilmiş sınıflandırma başarımları.

Girdi olarak kullanılan spektogramlar 500x500'lük olacak şekilde güncellenmiş ve ESA algoritmasına beslenmiştir. Bu besleme sonucunda eğitim başarımları %96.80 olarak Eğitim aşaması tamamlandıktan sonra sınıflandırma başarımları gözlemlenmek istemiştir. Sınıflandırma başarımları %96.52 olarak elde edilmiştir.

Girdi olarak kullanılan spektogramlar 600x600'lük olacak şekilde güncellenmiş ve ESA algoritmasına beslenmiştir. ESA ağı eğitildikten sonra çıktı analiz edilmiş ve başarımları %94.53 olarak gözlemlenmiştir.

Girdi boyutlarının değiştirilerek eğitim ve test başarımlarının gözlemlenmesi sonucu, elde edilen sonuçlar Tablo 6-3 ile gösterilmiştir.

Tablo 6-3 Girdi boyutlarına göre test ve eğitim başarımları.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
300x300 piksel boyutu ile sınıflandırma	300x300 piksel boyutuna sahip görüntülerin algoritmaya beslenmesi	96.84	96.9	96.94	96.9	96.9	0.9651	857dk 50sn
500x500 piksel boyutu ile sınıflandırma	500x500 piksel boyutuna sahip görüntülerin algoritmaya beslenmesi	96.8	96.44	96.46	96.44	96.44	0.96	2005dk 5sn
600x600 piksel boyutu ile sınıflandırma	600x600 piksel boyutuna sahip görüntülerin algoritmaya beslenmesi		94.53	94.86	94.53	94.58	0.9385	

6.4.2 Adaptif Öğrenme Algoritmaları


Farklı görüntü boyutlarına göre algoritmanın başarımının değerlendirilmesi sonrasında, 100x100'lük piksel boyutuna sahip olan görüntülerin kullanılarak analizlere devam edilmiştir. 100x100'lük piksel boyutlarına sahip olan veri seti ile elde edilen %97.72'lik başarımın iyileştirilmesi için Algoritma üzerinde değişiklik yapılması hedeflenmiştir. Bu hedef doğrultusunda ilk olarak iki adet adaptif öğrenme algoritması denenmiştir. Bu algoritmalar;

- OneCycleLR
- ReduceLROnPlateau

Algoritmalarıdır.

OneCycleLR yöntemi, derin öğrenme modellerinin eğitiminde performansın artırılması amacı ile kullanılmaktadır. Bu çalışma kapsamında, ESA algoritmasında bir önceki aşamalarda yapılan çalışmalar doğrultusunda sabit olarak kullanılan 10^{-3} öğrenme değerinin adaptif olarak başlangıçta artırılıp daha sonra azaltılarak hızlı ve verimli şekilde öğrenme aşamasının tamamlanması hedeflenmiştir. Bu çalışma iki kez tekrarlanarak başarımlar değerlendirilmiştir. İlk olarak öğrenme değeri 10^{-2} ile 10^{-3} aralığında alınarak

algoritma kořturulmuřtur. Bu kořturma sonrasında, Öğrenme başarıımı %97.88 olarak elde edilmiştir. Öğrenme grafiğı Şekil 6-13ile gösterildiğı gibidir.



Şekil 6-13 OneCycleLR algoritması 10-2 ile 10-3 aralığında eğitim sonuçları.

Test verileri ile test edilmesi sonrasında sınıflandırma başarıımının %97.47 olduğu gözlemlenmiştir. Algoritmanın belirtilen değerler ile çalıştırılması sonucunda aşağıdaki Şekil 6-14 ile gösterilmiş sonuçlar elde edilmiştir.

1	981		16		3				
2	2	993	3		1	1			
3	3	3	955	22	5	2		10	
4				995		1		4	
5	2	1	26	17	948	4		2	
6			1	53		946			
7			1				994	4	1
8	4		17	8		1	4	966	
9	2							4	994
	1	2	3	4	5	6	7	8	9


Predicted Class

Şekil 6-14 OneCycleLR algoritması 10^{-2} ile 10^{-3} aralığında sınıflandırma sonuçları.

Aynı algoritma üzerinde yer alan maksimum ve minimum öğrenme değeri 10^{-3} ile 10^{-4} olacak şekilde güncellenerek tekrar koşturulmuştur. Bu koşturma sonrasında, eğitim başarısının %96.34'e gerilediği, test verileri ile sınıflandırma başarımının %95.96'ya gerilediği gözlemlenmiştir.

Sonuçlardan da görüldüğü üzere OneCycleLR yöntemi kullanılarak başarımlar üzerinde bir artış sağlanamamıştır.

ReduceLROnPlateau yöntemi, OneCycleLR yöntemine benzer olarak öğrenme oranı değerini adaptif bir şekilde değiştirerek modelin performansını iyileştirmeyi amaçlamaktadır. Bu yöntem, modelde elde edilen doğrulama kaybını gözlemleyerek doğrulama kaybında bir iyileştirme olmaması durumunda öğrenme oranını değiştirmektedir. Bu doğrultuda, OneCycleLR yöntemi ile aynı maksimum ve minimum değerle kullanılmıştır. İlk olarak, 10^{-2} ile 10^{-3} değerleri ile algoritma koşturulmuştur. Bu doğrultuda eğitim başarımı %96.88 olarak elde edilmiştir. Elde edilen öğrenme başarımı Şekil 6-15 ile gösterildiği gibidir.



Şekil 6-15 ReduceLROnPlateau algoritması 10-2 ile 10-3 aralığında eğitim sonuçları.

Eğitim işlemi tamamlandıktan sonra test verileri ile sınıflandırma doğruluğuna yönelik ölçümler gözlemlenmiştir. Bu gözlem neticesinde sınıflandırma başarımı %96.48 olduğu görülmüştür. Elde edilen sonuç Şekil 6-16 ile gösterildiği gibidir.

1	949	10	16	1	21	1		2	
2	2	988	3		5	1		1	
3	5	14	905	21	37	8		10	
4			1	975	1	20		3	
5		1	13	17	964	3		2	
6				20		979		1	
7	1	1	1	2	2		976	16	1
8	2		17	5	1	1	16	958	
9	1		1					9	989
	1	2	3	4	5	6	7	8	9
Predicted Class									

Şekil 6-16 ReduceLROnPlateau algoritması 10-2 ile 10-3 aralığında sınıflandırma sonuçları.

Öğrenme oranları değiştirilerek aynı adımlar tekrarlanmıştır. Öğrenme değerleri minimum 10^{-3} ile maksimum 10^{-4} olacak şekilde algoritma koşturulmuştur. Bu koşum sonrasında öğrenme başarımı %96.30 olarak elde edilmiştir. Test verileri ile yapılan sınıflandırma ile sınıflandırma başarımı %95.66 olarak elde edilmiştir.

ReduceLROnPlateau yöntemi ile başarımın arttırılamadığı gözlemlenmiştir.

Adaptif Öğrenme Algoritmalarının denenmesi sonucunda elde edilen eğitim ve test başarımları Tablo 6-4 ile gösterildiği gibidir.


Tablo 6-4 Adaptif Öğrenme Algoritmalarının Eğitim ve Test Başarımları

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
OneCycleLR	OneCycleLR adaptif öğrenme algoritmasının kullanılması.(0.01 ile 0.001 aralığı)	97.88	97.47	97.56	97.47	97.48	0.9715	1025dk 42sn
OneCycleLR	OneCycleLR adaptif öğrenme algoritmasının kullanılması.(0.001 ile 0.0001 aralığı)	96.34	95.96	96.1	95.96	95.98	0.9545	1063dk 29sn
ReduceLROnPlateau	ReduceLROnPlateau adaptif öğrenme algoritmasının kullanılması.(0.01 ile 0.001 aralığı)	96.88	96.48	96.51	96.48	96.47	0.9604	810dk 53sn
ReduceLROnPlateau	ReduceLROnPlateau adaptif öğrenme algoritmasının kullanılması.(0.001 ile 0.0001 aralığı)	96.3	95.66	95.83	95.66	95.69	0.9511	1053dk 29sn

6.4.3 ESA Filtre Boyutlarına Yönelik Denemeler

Başarımı arttırmaya yönelik bir diğer çalışma ise ESA algoritmasında bulunan Beş adet evrişim katmanında kullanılmış olan 3x3'lük filtrelerin arttırılmasıdır. Bu doğrultuda, 5x5 ve 7x7'lik filtreler kullanılarak denemeler yapılmıştır.

Beş katmanda yer alan 3x3'lük filtreler 5x5 olarak değiştirilmiş ve bu doğrultuda ESA algoritması herhangi bir adaptif öğrenme algoritması kullanılmadan öğrenme değeri 10^{-3} olacak şekilde koşturulmuştur. Bu koşma sonrasında eğitim başarımı %97.47 olarak hesaplanmıştır. Elde edilen sonuçlar Şekil 6-17 ile gösterildiği gibidir.



Şekil 6-17 5x5'lik Evrişim filtreleri kullanımı ile elde edilen eğitim başarıımı.

Eğitim aşamasından sonra test verileri ile gerçekleştirilen sınıflandırma başarıımı %97.22 olarak gözlemlenmiştir. Elde edilen sonuçlar Şekil 6-18 ile gösterildiği gibidir.

1	984	1	6		8			1	
2	7	987	4		2				
3	10	5	952	1	17	1		14	
4			10	950	5	28		7	
5	2	2	22	3	966	4		1	
6			3	12		985			
7	1						988	8	3
8	6		10	1	4	7	23	949	
9	3							8	989
	1	2	3	4	5	6	7	8	9
	Predicted Class								

Şekil 6-18 5x5'lik Evrişim filtreleri kullanımı ile elde edilen sınıflandırma başarıımı.

Sonuçlardan da görüldüğü üzere, başarımlar üzerinde filtre boyutunun artırılması ile olumlu bir artış sağlanamamıştır.

Beş katmanda yer alan 3x3'lük filtreler 7x7 olarak değiştirilmiş ve bu doğrultuda ESA algoritması herhangi bir adaptif öğrenme algoritması kullanılmadan öğrenme değeri 10^{-3} olacak şekilde koşturulmuştur. Bu koşma sonrasında eğitim başarımları %96.38 olarak hesaplanmıştır. Eğitim aşamasından sonra test verileri ile gerçekleştirilen sınıflandırma başarımları %96.34 olarak gözlemlenmiştir.

Filtre boyutları ile elde edilen test ve eğitim başarımları Tablo 6-5 ile gösterildiği gibidir.


Tablo 6-5 Filtre boyutlarına göre elde edilen test ve eğitim başarımları.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Keskinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
5x5'lik filtre kullanımı	97.47	97.22	97.23	97.22	97.22	0.9688	890dk 18sn
7x7'lik filtre kullanımı	96.38	96.34	96.45	96.34	96.35	0.9589	890dk 36sn
9x9'lik filtre kullanımı	96.98	96.98	97	96.98	96.97	0.966	910dk 49sn

Sonuçlardan da görüldüğü üzere, başarımlar üzerinde filtre boyutunun artırılması ile olumlu bir artış sağlanamamıştır.

6.4.4 ESA Katman Sayısı Üzerinde Yapılan Denemeler


Bundan önceki yapılan denemelerde ESA yapısı olarak 5 Evrişim katmanına sahip bir ESA yapısı kullanılmıştır. Bu ESA yapısı ile yapılan denemeler sonrasında elde edilen başarımların değişimini gözlemlemek ve iyileştirme yapabilmek amacı ile Evrişim katmanları sayısı üzerinde değişiklik yapılması hedeflenmiştir. İlk önce katman sayısı Şekil 6-19 ile gösterildiği üzere 4 evrişim katmanına düşürülmüştür.



Şekil 6-19 4 Evrişim Katmanına sahip ESA yapısı.


Bu katman kullanılarak 100x100 girdi boyutuna sahip görüntüler ile eğitim ve test işlemi gerçekleştirilmiştir. Bu deneme sonrasında eğitim başarımı %97.28 olarak elde edilmiş ve Test Doğruluğu %97.44 olarak elde edilmiştir. Elde edilen diğer başarımlar kriterleri Tablo 6-6 ile gösterilmektedir.

Daha sonra Katman sayısı 6'ya çıkartılarak Şekil 6-20 ile gösterilen 6 katmanlı ESA yapısı kullanılmıştır.



Şekil 6-20 6 katmanlı ESA yapısı.

Bu yapıların kullanılması sonucunda elde edilen eğitim başarımı %98.26 olduğu, test başarımın ise 97.77 olduğu görülmüştür. 6 Katman kullanılan yapıda, başarımın arttığı gözlemlenmiştir. 6 Katmanlı ESA yapısına ait eğitim başarı değeri Şekil 6-21 ile test sonuçlarının gösterildiği karışıklık matrisi Şekil 6-22 ile gösterildiği gibidir.



Şekil 6-21 6 Katmanlı ESA Mimarisi kullanımı durumunda, eğitim başarıımı.

1	989		7		4				
2	1	990	5	1	2	1			
3	8	1	953	5	23	1		9	
4			1	986		7		6	
5	3	1	14	10	970	1		1	
6			2	26		971		1	
7	1					1	990	5	3
8	4		12	7	1	2	13	961	
9	9							2	989
	1	2	3	4	5	6	7	8	9


Şekil 6-22 6 Katmanlı ESA yapısına ait test sonuçları.

Elde edilen diğer başarıım kriterleri Tablo 6-6 ile gösterilmiştir.

Tablo 6-6 ESA katman yapılarına göre eğitim ve test başarımları

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
6 katmanlı ESA kullanımı	ESA katman sayısının 6'ya yükseltilmesi	98.26	97.77	97.78	97.77	97.77	0.9749	1000dk 41sn
4 katmanlı ESA kullanımı	ESA katman sayısının 4'e düşürülmesi.	97.28	97.44	97.54	97.44	97.46	0.9713	987dk 29sn

Ayrıca, 6 katmanlı ESA ile elde edilen başarılar göz önüne alınarak, iki sınıflı veri seti ile deneme gerçekleştirilmiştir. Bu deneme sonucunda, eğitim başarımları %99.13 olarak elde edilmiştir. Bu denemede, test doğruluğu %99.37 olarak elde edilmiştir. Bu denemeye ait başarımlar Tablo 6-7 ile gösterilmiştir. Ayrıca, elde edilen sonuçlar Şekil 6-23 ile gösterildiği gibidir.



Şekil 6-23 İki sınıflı veri seti ile 6-Katmanlı ESA kullanılması durumunda elde edilen sonuçlar.

Tablo 6-7 İki sınıflı veriseti ile 6 katmanlı ESA başarımları.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
6 katmanlı ESA (2 sınıflı veriseti)	2 sınıflı veri seti ile 6 katmanlı ESA kullanımı.	99.13	99.37	99.08	98.34	98.71	0.974	714dk 55sn

6.4.5 Önceden Eğitilmiş Sinir Ağlarının Başarımları

Önceden eğitilmiş Sinir Ağları kullanılarak başarımda artış sağlamak hedeflenmiştir. Bu doğrultuda, aşağıda belirtilmiş olan Önceden Eğitilmiş Sinir Ağları kullanılmıştır.

- Resnet50
- VGG16
- VGG19
- Alexnet
- GoogleNet

Resnet50 ağı, 50 katmana sahip bir model olup “artık bağlantılar” yapısının kullanılarak her katmanda elde edilen çıktılarının bir sonraki katmana girdi olabilmesi nedeniyle daha verimli ve etkin çalıştığını kanıtlamış bir ağ yapısıdır[29]. Bu doğrultuda, Resnet50 ağının son katmanı ile Spektogram görüntülerinin eğitilmesi ile %97.53'lük bir eğitim başarımları elde edilmiş olup, Eğitim Doğruluğu değeri %97.24 olarak elde edilmiştir. Elde edilen başarımların değerleri Tablo 6-8 ile gösterildiği gibidir.

VGG16 ağı, toplamda 16 katmana sahip bir sinir ağı yapısıdır. Bu 16 katmanın, 13 katmanı evrişim katmanı ve 3 katmanı ise tam bağlı katmandır[30]. Tez çalışması kapsamında, bu yapı alınarak son katmanı spektogram görüntüleri ile eğitilmiş ve bu doğrultuda VGG16 ağı koşturulmuştur. Bu koşturma sonucunda eğitim başarımları %96.79 olarak elde edilmiş olup, test başarımlarının doğruluğu %96.5 olarak elde edilmiştir. Elde edilen başarımların değerleri Tablo 6-8 ile gösterildiği gibidir.

VGG19 ağı, toplamda 19 katmana sahip bir sinir ağı yapısıdır. Bu 19 katmanın, 16 katmanı evrişim katmanı ve 3 katmanı ise tam bağlı katmandır [30]. Tez çalışması kapsamında, bu yapı alınarak son katmanı spektogram görüntüleri ile eğitilmiş ve bu doğrultuda VGG19 ağı koşturulmuştur. Bu koşturma sonucunda eğitim başarımları %96.39 olarak elde edilmiş olup,

test başarımının doğruluğu %96.16 olarak elde edilmiştir. Elde edilen başarım değerleri Tablo 6-8 ile gösterildiği gibidir.

Alexnet Sinir ağı, toplamda 8 katmandan oluşan bir sinir ağı yapısıdır. Bu 8 katmanın, 5 katmanı evrişim katmanı olarak, 3 katmanı ise tam bağlı katman olarak kullanılmaktadır[31]. Tez çalışması kapsamında, bu yapı alınarak son katmanı spektogram görüntüleri ile eğitilmiş ve bu doğrultuda Alexnet ağı koşturulmuştur. Bu koşturma sonucunda eğitim başarımı %97 olarak elde edilmiş olup, test başarımının doğruluğu %96.69 olarak elde edilmiştir. Elde edilen başarım değerleri Tablo 6-8 ile gösterildiği gibidir.


GoogLeNet, "Inception" olarak adlandırılan özgün bir modüler mimariye sahiptir ve bu mimari, farklı boyutlarda filtrelerin aynı katman içinde paralel olarak uygulanmasına olanak tanımaktadır. toplamda 22 derin katmandan oluşur ve daha derin katmanların kullanılmasına rağmen, model parametre sayısını azaltmak amacıyla tam bağlı katmanların sayısını minimumda tutar. Ayrıca, bu mimari, hesaplama maliyetlerini ve bellek kullanımını azaltırken doğruluğu artırmak için 1x1 konvolüsyonları yoğun olarak kullanır. Bu yapı, derin ağların verimliliğini önemli ölçüde artırmaktadır[31]. Tez çalışması kapsamında, bu yapı alınarak son katmanı spektogram görüntüleri ile eğitilmiş ve bu doğrultuda GoogleNet ağı koşturulmuştur. Bu koşturma sonucunda eğitim başarımı %97.19 olarak elde edilmiş olup, test başarımının doğruluğu %96.7 olarak elde edilmiştir. Elde edilen başarım değerleri Tablo 6-8 ile gösterildiği gibidir.

Tablo 6-8 Önceden Eğitilmiş Sinir Ağları ile elde edilmiş Test ve Eğitim başarımları.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Resnet50	97.53	97.24	97.25	97.24	97.24	0.969	1084dk 46sn
VGG16	96.79	96.5	96.53	96.5	96.49	0.9606	1020dk 51sn
VGG19	96.39	96.16	96.27	96.16	96.17	0.9568	1474dk 1sn
AlexNET	97	96.96	97.01	96.96	96.95	0.9658	471dk 30sn
GoogleNet	97.19	96.7	96.81	96.7	96.71	0.9629	489dk 38sn

Tablo 6-8 ile belirtilmiş sonuçlardan da görüldüğü üzere başarım üzerinde artış sağlanamamıştır. Ancak, önceden eğitilmiş sinir ağların kullanılması ile en yüksek başarım

Resnet50 ile elde edilmiş olup, eğitim sonuçları Şekil 6-24 ile ve test sonuçları ise Şekil 6-25 ile gösterilmektedir.



Şekil 6-24 Resnet50 eğitim başarımlar sonucunu.


1	979	1	8		10	1		1	
2	1	990	2		5	1		1	
3	2	6	944	12	17	4		15	
4			3	946	7	37		7	
5	5	1	18	6	966	3		1	
6			3	18	1	977	1		
7					1		994	4	1
8	4		16	5	2	1	13	959	
9	1							2	997
	1	2	3	4	5	6	7	8	9

True Class

Predicted Class

Şekil 6-25 Resnet50 test başarımlar sonucunu.

Önceden eğitilmiş sinir ağları ile en yüksek başarımlar Resnet50 ile elde edilmiştir. Bu durumun iki sınıflı veri seti üzerindeki başarımının gözlemlenmesi amacı ile iki sınıflı veri seti kullanılarak deneme gerçekleştirilmiştir. Bu deneme sonucunda elde edilen test sonuçları Şekil 6-26 ile gösterildiği gibidir. Ayrıca, Resnet50 ile iki sınıflı veri setinin kullanılması ile elde edilen başarımlar Tablo 6-9 ile gösterilmektedir.



Şekil 6-26 İki sınıflı veri seti ile Resnet50 kullanılması durumunda elde edilen test sonuçları.


Tablo 6-9 Resnet50 ile iki sınıflı verilerin kullanılması durumunda elde edilen sonuçlar.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Resnet50	98.79	98.81	97.75	97.38	97.57	9.951	815dk 5sn

6.4.6 Klasik Makine Öğrenmesi Yöntemlerinin Kullanılması

Tez çalışması kapsamında bu aşamaya kadar elde edilmiş olan en yüksek başarımlar 6 katmanlı ESA yapısının kullanılması ile elde edilmiştir. Bu sebep ile 6 katmanlı ESA yapısı

sonrasında elde edilmiş öznitelikler alınarak klasik makine öğrenmesi algoritmalarına uygulanarak başarımları gözlemlenmiştir. Bu yöntem Şekil 6-27 ile gösterilmektedir.



Şekil 6-27 Klasik Makine Öğrenmesi Yöntemlerinin kullanımına yönelik yapı.

Bu doğrultuda aşağıda belirtilen makine öğrenmesi yöntemleri kullanılmıştır.


- Coarse Tree
- Fine KNN
- Fine Tree
- Linear SVM
- Medium Gaussian SVM
- Medium KNN
- Medium Tree

Bu yöntemler ile elde edilen eğitim ve test başarımları Tablo 6-10 ile gösterilmektedir.


Tablo 6-10 Klasik Makine Öğrenmesi algoritmaları ile elde edilen başarımlar.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Coarse Tree	51.7	51.69	37.46	39.94	35.35	0.433	64.179 sn
Fine KNN	92.6	92.59	93.67	92.79	93.11	0.9149	2401.6 sn
Fine Tree	85.7	58.69	86.62	84.45	85.32	0.8356	95.596sn
Linear SVM	98.8	98.04	98.06	97.04	98.05	0.978	4327 sn
Medium Gaussian SVM	94.4	94.42	95.67	93.51	94.46	0.9359	8184.2 sn
Medium KNN	93.8	93.77	94.86	93.94	94.23	0.9284	2376.9sn
Medium Tree	76.5	76.45	70.36	69.27	68.16	0.729	63.884sn

Klasik makine öğrenmesi algoritmaları ile elde edilen sonuçlar incelendiğinde Lineer DVM yönteminin başarımı arttırdığı görülmektedir. Çalışma boyunca elde edilen en yüksek başarımlar Lineer DVM yöntemi ile elde edilmiştir. Bu yöntemle ait eğitim başarımları Şekil 6-28 ile, test başarımları Şekil 6-29 ile gösterilmektedir.




Şekil 6-28 Lineer DVM yöntemiine ait eğitim sonuçları.



Şekil 6-29 Lineer DVM yöntemine ait test sonuçları.

Lineer DVM yöntemi ile elde edilen başarımlar sonrasında, iki sınıflı veri seti ile deneme gerçekleştirilmiştir. Dokuz sınıflı veri seti ile yapıldığı gibi, ilk önce 6 katmanlı ESA algoritması ile öznitelik çıkartımları yapılmış olup, sonra klasik makine öğrenmesi

algoritmaları kullanılmıştır. Bu deneme sonrasında, elde edilen başarımlar tablo ile gösterildiği gibidir. Elde edilen sonuç Şekil 6-30 ile gösterildiği gibidir.



Şekil 6-30 İki sınıflı ver seti ile Lineer DVM yönteminin kullanılması ile elde edilen sonuç.

Tablo 6-11 İki sınıflı veriseti ile Lineer DVM başarımları.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Linear SVM	99.7	99.4	98.54	99.03	98.78	0.976	273sn

6.4.7 Sınıflandırma Yöntemlerinin Başarımlarının Karşılaştırılması

Sınıflandırma yöntemleri ile başarımların gözlemlenmesi amacı ile birçok farklı yöntem için deneme yapılmıştır. Bu denemelere yönelik bilgilerin, başarımların ve elde edilen sonuçların yer aldığı bilgiler

Tablo 6-12 ile gösterilmiştir.

Tablo 6-12 Sınıflandırma için kullanılan yöntemlerin karşılaştırması

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
Beş Tarama Segmenti(100x100 piksel)	Radar verilerine ait beş tarama segmentinin tek bir spektrogram haline getirilerek algoritmalar uygulanması	97.99	97.72	97.74	97.72	97.73	0.9744	885dk 50 sn
Tek Tarama Segmenti	Radar verilerindeki en yüksek yansımaya sahip segmentin alınarak algoritma ya uygulanması	91.88	91.69	92.07	91.69	91.72	0.9065	854dk 24sn

Tablo 6-13 devam ediyor.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Keskinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
300x300 piksel boyutu ile sınıflandırma	300x300 piksel boyutuna sahip görüntülerin algoritma ya beslenmesi	96.84	96.9	96.94	96.9	96.9	0.9651	857dk 50sn
500x500 piksel boyutu ile sınıflandırma	500x500 piksel boyutuna sahip görüntülerin algoritma ya beslenmesi	96.8	96.44	96.46	96.44	96.44	0.96	2005dk 5sn
600x600 piksel boyutu ile sınıflandırma	600x600 piksel boyutuna sahip görüntülerin algoritma ya beslenmesi		94.53	94.86	94.53	94.58	0.9385	
OneCycleLR	OneCycleLR adaptif öğrenme algoritmasının kullanılması.(0.01 ile 0.001 aralığı)	97.88	97.47	97.56	97.47	97.48	0.9715	1025dk 42sn

Tablo 6-14 devam ediyor.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
OneCycleLR	OneCycleLR adaptif öğrenme algoritmasının kullanılması.(0.001 ile 0.0001 aralığı)	96.34	95.96	96.1	95.96	95.98	0.9545	1063dk 29sn
ReduceLR OnPlateau	ReduceLR OnPlateau adaptif öğrenme algoritmasının kullanılması.(0.01 ile 0.001 aralığı)	96.88	96.48	96.51	96.48	96.47	0.9604	810dk 53sn
ReduceLR OnPlateau	ReduceLR OnPlateau adaptif öğrenme algoritmasının kullanılması.(0.001 ile 0.0001 aralığı)	96.3	95.66	95.83	95.66	95.69	0.9511	1053dk 29sn
5x5'lik filtre kullanımı		97.47	97.22	97.23	97.22	97.22	0.9688	890dk 18sn
7x7'lik filtre kullanımı		96.38	96.34	96.45	96.34	96.35	0.9589	890dk 36sn
9x9'lik filtre kullanımı		96.98	96.98	97	96.98	96.97	0.966	910dk 49sn

Tablo 6-15 devam ediyor.

Kullanılan Yöntem	Açıklama	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
6 layer ESA kullanımı	ESA katman sayısının 6'ya yükseltilmesi	98.26	97.77	97.78	97.77	97.77	0.9749	1000dk 41sn
4 layer ESA kullanımı	ESA katman sayısının 4'e düşürülmesi.	97.28	97.44	97.54	97.44	97.46	0.9713	987dk 29sn
Resnet50		97.53	97.24	97.25	97.24	97.24	0.969	1084dk 46sn
VGG16		96.79	96.5	96.53	96.5	96.49	0.9606	1020dk 51sn
VGG19		96.39	96.16	96.27	96.16	96.17	0.9568	1474dk 1sn
AlexNET		97	96.96	97.01	96.96	96.95	0.9658	471dk 30sn
GoogleNet		97.19	96.7	96.81	96.7	96.71	0.9629	489dk 38sn
Coarse Tree		51.7	51.69	37.46	39.94	35.35	0.433	64.179 sn
Fine KNN		92.6	92.59	93.67	92.79	93.11	0.9149	2401.6 sn
Fine Tree		85.7	58.69	86.62	84.45	85.32	0.8356	95.596sn
Linear SVM		98.8	98.04	98.06	97.04	98.05	0.978	4327 sn
Medium Gaussian SVM		94.4	94.42	95.67	93.51	94.46	0.9359	8184.2 sn
Medium KNN		93.8	93.77	94.86	93.94	94.23	0.9284	2376.9sn
Medium Tree		76.5	76.45	70.36	69.27	68.16	0.729	63.884sn

Sonuçlar gözlemlendiğinde, en yüksek başarıma sahip üç yöntem sırası ile aşağıdaki gibidir.

- Linear DVM
- 6 Layer ESA
- 5 Layer, 100x100 görüntü boyutuna sahip ESA yapısı

Bu üç yöntemin başarımı %97'nin üzerinde olduğu görülmektedir. Veri setinin alındığı [13] çalışmada elde edilmiş olan başarımların üzerinde olduğu görülmektedir. Belirtilen çalışmada elde edilmiş olan başarımlar, Tüm drone tipleri ile yapılmış eğitimde %90 olduğu belirtilmiştir[13]. Bu çalışmada kullanılan yöntemlerin birçoğu ile bu başarımın üzerine geçilmiştir.

Benzer çalışmalarda elde edilmiş başarımlar ile bu tez çalışmasında elde edilmiş başarımların kıyaslaması Tablo 6-13 ile gösterilmektedir.

Tablo 6-16 Benzer çalışmalar ile tez çalışmasının başarımların karşılaştırması.

Yazar	Makale	Yıl	Sınıf Sayısı	Kullanılan Yöntem	En yüksek Başarımlar
Alexander Karlsson, M. Jansson ve M. Hämäläinen'in	Model-Aided Drone Classification Using Convolutional Neural Networks [13]	2022	9	ESA	90%
D. White, M. Jahangir, J. P. Wayman, S. J. Reynolds, J. P. Sadler ve M. Antoniou	Bird and Micro-Drone Doppler Spectral Width and Classification [14]	2023	2	ESA	90%
Wen Jiang,Yanping Wang ,Yang Li,Yun Lin ve Wenjie Shen	Radar Target Characterization and Deep Learning in Radar Automatic Target Recognition: A Review [15]	2023	2	ESA	96.86%
Harish Chandra Kumawat, Mainak Chakraborty, A. Arockia Basil Raj ve Sunita Vikrant Dhavale	DIAT-μSAT: micro-Doppler Signature Dataset of Small Unmanned Aerial Vehicle (SUAV) [16]	2022	4	VGG16	95%
			4	VGG19	97%
R. M. Narayanan, B. Tsang, ve R. Bharadwaj	Classification and Discrimination of Birds and Small Drones Using Radar Micro-Doppler Spectrogram Images [17]	2023	5	DVM	96%
Bu tez çalışması		2024	9	ESA-DVM	%98.04
			2	ESA-DVM	%99.4

Ayrıca bu analizlerin yanı sıra, önerilen yöntemin drone sınıfından diğer sınıfları ayırıştırma kabiliyetini anlamak için veri seti iki sınıflı ayırt edecek şekilde düzenlenmiştir. Önerilen yöntemlerde iki sınıflı veri seti kullanılması durumunda elde edilen başarımlar Tablo 6-17 ile gösterildiği gibidir.

Tablo 6-17 İki sınıflı veri seti ile elde edilmiş sonuçlar.

Kullanılan Yöntem	Eğitim Başarısı	Test Başarısı(Doğruluk)	Kesinlik(Makro Ortalama)	Duyarlılık(Makro Ortalama)	F1-Score (Makro Ortalama)	KAPPA	İşlem Süresi
İkili sınıf, Beş Tarama Segmenti(100x100 piksel)	99.19	99.27	98.38	98.66	98.52	0.970	711dk 56sn
6 katmanlı ESA (2 sınıflı veriseti)	99.13	99.37	99.08	98.34	98.71	0.974	714dk 55sn
Resnet50	98.79	98.81	97.75	97.38	97.57	9.951	815dk 5sn
Linear SVM	99.7	99.4	98.54	99.03	98.78	0.976	273sn

7. SONUÇ VE ÖNERİLER

Günümüzde drone üretimlerinin yaygınlaşması ile kolay ulaşılabilir olması nedeniyle, farklı alanlarda kullanımı yaygınlaşmıştır. Bu kullanımların yaratabileceği riskler nedeni ile dronelerin tespitinin farklı sensörler ile tespitinin önemi her geçen gün artmaktadır. Bu çalışma kapsamında, 77 GHz'lik bir FMCW radarına ait veriler ile tespit ve sınıflandırma üzerine çalışma yapılmıştır. Açık veri setinin verildiği çalışmada gerçekleştirilen sınıflandırma başarımları değeri %90 olduğu görülmektedir. Bu çalışma, ilk olarak veri setinin yararlanıldığı çalışma ile elde edilen başarımların artırılması hedeflenmiştir. Bu çalışma kapsamında gerçekleştirilen çalışmalarda, kullanılan yöntemlerin çoğunda %90'ın üzerinde başarımlar sağlanmıştır. En yüksek başarımların elde edildiği teknikler sırası ile, ESA ile elde edilmiş olan özneliklerin çıkartımı ile Lineer SVM yönteminin kullanılması, 6 Evrişim Katmanına sahip ESA'nın kullanılması, 5 Evrişim katmanına sahip ESA kullanılması olarak sıralanabilir. Bu üç yöntem dışında da kullanılan birçok yöntemde %95 üzeri başarımlar elde edilmiştir. Ayrıca, ESA ile ilgili yöntemler dışında temel olarak görülen bazı klasik makine öğrenmesi algoritmaları ile denemeler yapılmış, Lineer DVM dışında birçok algoritmanın %90'dan yüksek başarımlar ile çalıştığı gözlemlenmiştir. %90'dan az başarımlar elde edilen algoritmalar, Fine Tree algoritması, Medium Tree algoritması ve Coarse Tree algoritmalarıdır.

Ayrıca, bu çalışma kapsamında görselleştirilmiş spektogram görüntüleri içerisinde yer alan mikro-doppler izlerine sahip görüntülerin piksel boyutları/çözünürlükleri değiştirilerek farklı denemeler yapılmış, bu denemeler sonucunda Radar verileri ile ESA kullanımı ile Drone, kuş ve insan gibi sınıflandırma yöntemleri üzerinde etkileri gözlemlenmiş, işlem süreleri dışında başarımlar olarak büyük bir etkiye sahip olmadığı gözlemlenmiştir.

Bu çalışmada, kullanılan yöntemlerde ana odak noktası ESA'lar olarak belirlenmiştir. İlk olarak, 5 Evrişim katmanına sahip bir ESA oluşturulmuştur. İlk denemeler bu ESA ile gerçekleştirilmiş, girdi olarak alınan spektogram piksel boyutu/çözünürlüğü ile denemeler sağlanmıştır. Daha sonra, oluşturulmuş bu ESA içerisinde yer alan Evrişim katmanlarının filtre boyutları ile denemeler yapılmıştır. İlk durumda, bu filtre boyutları 3x3'lük olarak alınmış, daha sonra bu filtre boyutları 5x5 ve 7x7 olacak şekilde denemeler sağlanmıştır. Bu denemeler sonucunda, istenen iyileşme sağlanamamıştır ve işlem süresinde filtre boyutunun

artması ile artış gözlemlenmiştir. Daha sonra, ESA'nın iyileştirilmesi ve etkilerinin gözlemlenmesi amacı ile 4 Evrişim katmanlı ve 6 Evrişim katmanlı olacak şekilde ESA yapısı güncellenerek başarıma etkisi gözlemlenmiş olup, 6 Evrişim Katmanı olan ESA yapısının daha yüksek başarımla çalıştığı görülmüştür.

Veri seti ve başarımla hedefinin referans alındığı çalışmada[13], elde edilen ham veriler üzerinde SGO iyileştirmesi sağlanarak başarımla artırılması hedeflenmiştir. Bu çalışmada ham veriler alınarak, kullanılan makine öğrenmesi yöntemi ile başarımla iyileştirilmesi hedeflenmiş ve başarılı bir şekilde başarımla üzerinde iyileştirme sağlanmıştır. Veri setinin büyüklüğü, içeriğinde yer alan hedeflerin fazlalığı ve çeşitliliği göz önüne alındığında %98.04'lık bir başarımla umut vadecici olduğu görülmektedir.

Sonuçlardan görüldüğü üzere klasik makine öğrenmesi yöntemlerinin günümüzde çözüm aranan problemler için de başarılı bir yöntem olarak kullanılabileceği görülmektedir. Klasik makine öğrenmesi yöntemlerinden DVM yöntemi ile ESA'ların birlikte kullanılarak kuş-drone ayırma yönelik başarılı bir sınıflandırıcı olarak kullanılması, iki sınıflı (Kuş ve drone) sınıflandırma için %99.4 başarımla umut vadetmektedir.

KAYNAKLAR

- [1] *'Turkey closes Diyarbakir airport for month after drone attack 'by PKK'', The Times*, Aug. 2022. [Online]. Available: [thetimes.co.uk/article/turkey-closes-diyarbakir-airport-for-month-after-drone-attack-by-pkk-gmcj8skfz](https://www.thetimes.co.uk/article/turkey-closes-diyarbakir-airport-for-month-after-drone-attack-by-pkk-gmcj8skfz)
- [2] *Drone attack in abu dhabi kills 3 wounds 6 - cbc news*. 2022. [Online]. Available from: [cbc.ca/news/world/abu-dhabi-drone-attack-1.6317555](https://www.cbc.ca/news/world/abu-dhabi-drone-attack-1.6317555)
- [3] *Small drones are giving ukraine an unprecedented edge - wired*. 2022. [Online]. Available from: [wired.com/story/drones-russia-ukraine-war/](https://www.wired.com/story/drones-russia-ukraine-war/)
- [4] *Ukraine: How drones are changing the way of war - science - in-depth reporting on science and technology - DW*. 2022. [Online]. Available from: [dw.com/en/ukraine-how-drones-are-changing-the-way-of-war/a-61681013](https://www.dw.com/en/ukraine-how-drones-are-changing-the-way-of-war/a-61681013)
- [5] M. I. Skolnik, *Radar Handbook*, 3rd ed. New York, NY, USA: McGraw-Hill, 2008.
- [6] M. A. Richards, *Fundamentals of Radar Signal Processing*. New York, NY, USA: McGraw-Hill, 2005.
- [7] N. Levanon and E. Mozeson, *Radar Signals*. Hoboken, NJ, USA: Wiley-Interscience, 2004.
- [8] B. R. Mahafza, *Radar Systems Analysis and Design Using MATLAB*, 3rd ed. Boca Raton, FL, USA: CRC Press, 2013.
- [9] D. R. Langsdorf, "The Kettering Bug: Ordnance's Secret Weapon of World War I," *IEEE Spectrum*, vol. 4, no. 9, pp. 82-85, Sept. 1967.
- [10] G. C. Herring, "Ryan Firebee: The Pioneer of Target Drones," *IEEE Aerospace and Electronic Systems Magazine*, vol. 14, no. 10, pp. 17-22, Oct. 1999.
- [11] Zion Market Research, "Drone Market Size – Global Industry Analysis, Share, Growth, Trends, and Forecast, 2023 – 2030," [Online].

Available:zionmarketresearch.com/report/drone-market-size. [Accessed: Aug. 11, 2024].

- [12] J. L. V. Barbosa, C. A. Boano, P. D. Gaspar, J. H. Kleinschmidt, and M. M. Montano, "A Comprehensive Survey of Machine Learning Applied to Radar Signal Processing," *arXiv preprint arXiv:2009.13702*, 2020. Available:arxiv.org/abs/2009.13702.
- [13] Karlsson, A., Jansson, M., & Hämmäläinen, M. (2022). *Model-Aided Drone Classification Using Convolutional Neural Networks*. 2022 IEEE Radar Conference (RadarConf22), 1-9. doi:10.1109/RADARCONF2248738.2022.9764194.
- [14] D. White, M. Jahangir, J. P. Wayman, S. J. Reynolds, J. P. Sadler and M. Antoniou, "Bird and Micro-Drone Doppler Spectral Width and Classification," 2023 24th International Radar Symposium (IRS), Berlin, Germany, 2023, pp. 1-10, doi: 10.23919/IRS57608.2023.10172408.
- [15] J. Wang, Y. Li, Y. Lin, and W. Shen, "Radar Target Characterization and Deep Learning in Radar Automatic Target Recognition: A Review," *Remote Sensing*, vol. 15, no. 15, pp. 3742, Aug. 2023, doi: 10.3390/rs15153742.
- [16] Harish Chandra Kumawat, Mainak Chakraborty, A. Arockia Bazil Raj, Sunita Vikrant Dhavale, September 21, 2022, "DIAT- μ SAT: micro-Doppler Signature Dataset of Small Unmanned Aerial Vehicle (SUAV)", *IEEE Dataport*, doi: 10.21227/1x2q-8v62.
- [17] R. M. Narayanan, B. Tsang, and R. Bharadwaj, "Classification and Discrimination of Birds and Small Drones Using Radar Micro-Doppler Spectrogram Images," *Signals*, vol. 4, no. 2, pp. 337-358, 2023, doi: 10.3390/signals4020018.
- [18] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.

- [19] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. Cambridge, MA, USA: MIT Press, 2012
- [20] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016.
- [21] Kim, P. , "Convolutional Neural Network", *MATLAB Deep Learning*, pp. 121–147, 2017, doi:10.1007/978-1-4842-2845-6_6.
- [22] N. Galanis, P. Vafiadis, K. Mirzaev, and G. A. Papakostas, "Convolutional Neural Networks: A Roundup and Benchmark of Their Pooling Layer Variants," *Algorithms*, vol. 15, no. 11, pp. 391, 2022, doi: 10.3390/a15110391.
- [23] Farhad Maleki, Katie Ovens, Keyhan Najafian, Behzad Forghani MEng, Caroline Reinhold, Reza Forghani, "Overview of Machine Learning Part 1: Fundamentals and Classic Approaches", *Neuroimaging Clinics of North America*, vol. 30, issue 4, November 2020, doi:doi.org/10.1016/j.nic.2020.08.007.
- [24] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed. New York, NY, USA: Springer, 2009
- [25] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995. doi: 10.1007/BF00994018.
- [26] Onkar Manjrekar, Milorad Duduković, "Identification of flow regime in a bubble column reactor with a combination of optical probe data and machine learning technique", *Chemical Engineering Science*, vol. 2, May 2019, doi:doi.org/10.1016/j.cesx.2019.100023.
- [27] Rahul Katarya, Ashutosh Raturi, Abhinav Mehndiratta, Abhinav Thapper, "Impact of Machine Learning Techniques in Precision Agriculture", *2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning*

and Internet of Things (ICETCE), pp. 1-6, February 2020, doi:
10.1109/ICETCE48199.2020.9091741.

- [28] Paul Czodrowski, "Count on kappa", *Journal of Computer-Aided Molecular Design*, vol. 28, pp. 1049–1055, July 2014, doi:10.1007/s10822-014-9759-6
- [29] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
- [30] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *2015 International Conference on Learning Representations (ICLR)*, San Diego, CA, USA, 2015, [Online]. Available: arxiv.org/abs/1409.1556
- [31] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017, doi: 10.1145/3065386.
- [32] W. Jiang, Y. Wang, Y. Li, Y. Lin, and W. Shen, "Radar Target Characterization and Deep Learning in Radar Automatic Target Recognition: A Review," *Remote Sens.*, vol. 15, no. 15, p. 3742, 2023. doi: 10.3390/rs15153742.