

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

HAVA ARAÇLARINA AİT GÖRÜNTÜLERİN SINIFLANDIRILMASI

**HAZIRLAYAN
HAMDİ EMRE KUL**

YÜKSEK LİSANS TEZİ

ANKARA – 2025

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

HAVA ARAÇLARINA AİT GÖRÜNTÜLERİN SINIFLANDIRILMASI

**HAZIRLAYAN
HAMDİ EMRE KUL**

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ DENİZ KARAÇOR

ANKARA – 2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

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

Tez Savunma Tarihi: 14 / 04 / 2025

Tez Adı: Hava Araçlarına Ait Görüntülerin Sınıflandırılması

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

İmza

Dr. Öğr. Üyesi Deniz KARAÇOR (Başkent Üniversitesi)

.....

Prof. Dr. Hamit Erdem (Başkent Üniversitesi)

.....

Prof. Dr. Mehmet Emin Tağluk (İnönü Üniversitesi)

.....

ONAY

Prof. Dr. Dilek ÇÖKELİLER SERDAROĞLU

Fen Bilimleri Enstitüsü Müdürü

Tarih: / /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih:14 /04 /2025

Öğrencinin Adı, Soyadı: Hamdi Emre KUL

Öğrencinin Numarası: 22120360

Anabilim Dalı: Elektrik Elektronik Mühendisliği

Programı: Elektrik Elektronik Mühendisliği Tezli Yüksek Lisans Programı

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğr. Üyesi Deniz KARAÇOR

Tez Başlığı: Hava Araçlarına Ait Görsellerin Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 60 sayfalık kısmına ilişkin, 25 / 04 /2025 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %9'dur. Uygulanan filtrelemeler:

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

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

Öğrenci İmzası:.....

ONAY

Tarih: ... / ... / 2025

Öğrenci Danışmanı:

Dr. Öğr. Üyesi Deniz KARAÇOR

.....

Hamdi Emre KUL

Aileme...

Ankara-2025

TEŞEKKÜR

Yüksek lisans boyunca yardımları, yönlendirmeleri ve destekleriyle tez çalışmamda bana yardımcı olan, her zaman iyimserliği ve bilgeliği ile bu süreçte hep destek olan, bu çalışmaya bakış açısıyla birlikte, ilerlenemez dediğim noktalarındaki yardımlarıyla daha da anlam katan hocam Dr. Deniz KARAÇOR'a saygılarımı sunarım.

Hayatım boyunca her zaman arkamda olan, emeklerini ve yardımlarını esirgemeyen, fedakarlıklarını, güvenlerini, sevgilerini ve desteklerini her zaman hissettiğim annem Hale KUL'a, babam Murat KUL'a ve canım kardeşim Hilal Gökçe KUL'a en derin saygı ve sevgilerimi sunarım. Bu yoğun dönemde her zaman yanımda oldunuz.

Tüm zorluklara rağmen desteğini hiçbir zaman esirgemeyen, başarılarımla her zaman gurur duyan Sırdaşıma desteği, yardımları ve sabrı için çok teşekkür ederim. İyi ki hayatımdasın.

Ayrıca, tezim boyunca yardım ve desteklerini esirgemeyen çocukluk arkadaşlarıma ve iş arkadaşlarıma teşekkür ederim.

ÖZET

Hamdi Emre KUL

HAVA ARAÇLARINA AİT GÖRÜNTÜLERİN SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2025

Bu çalışmada, belirli bir gruba ait askeri uçakların sınıflandırılması, sınıflandırma performanslarının değerlendirilmesi ve geliştirilmesi amaçlanmıştır. Uçaklarda sınıflandırma, başka ülkelerin tehdidini algılama, ülke sınırlarının güvenliğini sağlama, ticari uçuşlar ve askeri hava trafiği arasında etkili bir koordinasyon sağlama açısından büyük bir önem taşımaktadır. Sınıflandırma yapmak için kullanılan algoritmalarda, bir yapay sinir ağı olan Convolutional Neural Network (CNN) ve makine öğrenmesi olan Support Vector Machine (SVM) yöntemleri kullanılmıştır. CNN, görüntü veya başka veri çeşitlerini filtreler ya da çekirdekler (Kernel) aracılığıyla işleyerek verinin özelliklerini otomatik olarak öğrenmek üzerine kurulu bir mimaridir. SVM ise sınıflandırma ya da regresyon için kullanılan bir makine öğrenme algoritmasıdır. Verileri uzayda maksimum aralıkla ayıran hiper düzlemi bularak sınıflandırma yapmaktadır. Ayrıca, çekirdek yöntemlerini kullanarak doğrusal olmayan problemler için çözümler de sunabilmektedir. Bu tür sınıflandırma yöntemlerin etkinliği, büyük ölçüde kullanılan veri setlerinin kapsamı ve çeşitliliğiyle doğrudan bağlantılıdır.

Bu araştırmada, Shayan Khos tarafından oluşturulan ve sekiz farklı uçak tipini içeren, toplam 4990 adet uçak görselinden oluşan bir veri seti kullanılmıştır. Bu veri seti üzerinde CNN ve CNN-SVM modeli uygulanarak sınıflandırma gerçekleştirilmiştir. Bu modellerin performanslarını değerlendirebilmek amacıyla, içerisindeki bazı hiper parametreler değiştirilerek elde edilen sonuçlar karşılaştırılmıştır. İlk olarak, bu veri seti doğrudan CNN modeline uygulanmış ve CNN içerisindeki parametreler (öğrenme seçeneği, ilk öğrenme oranı değeri ve periyot sayıları) değiştirilerek bir karşılaştırma yapılmıştır. Daha sonrasında, CNN mimarisi yalnızca öznitelik çıkarımı için kullanılmış; bu öznitelikler, SVM algoritması ile sınıflandırılarak çıkan sonuçlar analiz edilmiştir. CNN ve CNN-SVM modellerine ayrı ayrı veri artırma işlemi uygulanarak doğruluk oranlarındaki değişimler gözlemlenmiştir. Elde edilen sonuçlar göz önüne alındığında doğrudan CNN'e verilen ve artırma işlemi

uygulanan veri setinin, 80 epok (Epoch) deęerinde bařlangıç öğrenme oranı (Initial Learn Rate) 0,001 olarak ayarlanmış ve sgdm algoritması kullanılarak eğitildięi senaryoda %96,52 test doęruluk oranı ile en yüksek performansa ulařtıęı tespit edilmiřtir.

ANAHTAR KELİMELELER: Askeri Uçak, CNN, SVM, Veri Artırma, Görüntü Sınıflandırma



ABSTRACT

Hamdi Emre KUL

CLASSIFICATION OF AIRCRAFT IMAGES

Başkent University Institute of Science

Department of Electrical and Electronics Engineering

2025

The aim of this study is to classify military aircraft belonging to a specific group, to evaluate the classification performance and to improve the results. Aircraft classification is important for detecting potential threats from other nations, ensuring the security of national borders, and facilitating effective coordination between commercial flights and military air traffic. The classification algorithms used in this study include the Convolutional Neural Network (CNN), an artificial neural network, and the Support Vector Machine (SVM), a machine learning algorithm. CNN is designed to automatically learn data features by processing different types of input, such as images, through filters or kernels. SVM, on the other hand, is a machine learning algorithm used for classification and regression tasks. It performs classification by identifying the hyperplane that maximises the distance between data points in the feature space. In addition, by using kernel methods, SVM can also provide solutions to non-linear problems. The effectiveness of such classification methods is highly dependent on the size and diversity of the data sets used.

In this research, a dataset consisting of 4,990 aircraft images of eight different aircraft types created by Shayan Khos was used. Classification was performed on this dataset using both CNN and CNN-SVM models. To evaluate the performance of these models, various hyperparameters were adjusted and the resulting results were compared. First, the dataset was applied directly to the CNN model and a comparison was made by modifying internal parameters of the CNN, such as the learning option, the initial learning rate and the number of epochs. Subsequently, the CNN architecture was used exclusively for feature extraction and these features were classified using the SVM algorithm and the results were analysed. Data augmentation was applied separately to both the CNN and CNN-SVM models, and the differences in accuracy were observed. The results showed that the scenario where the augmented dataset was fed directly into the CNN model, trained for 80 epochs with an initial learning rate of 0.001 using the sgdm algorithm, achieved the highest performance with a test accuracy of 96.52%.

KEYWORDS: Military Aircraft, CNN, SVM, Data Augmentation, Image Classification

İÇİNDEKİLER

TEŞEKKÜR	i
ÖZET	ii
ABSTRACT.....	iv
İÇİNDEKİLER.....	v
TABLolar LİSTESİ	viii
ŞEKİLLER LİSTESİ	ix
SİMGELER VE KISALTMALAR LİSTESİ.....	x
1. GİRİŞ	1
1.1. Literatürdeki Çalışmalar	2
2. MATERYAL	5
2.1. Veri Setine İlişkin Genel Bilgilendirme	5
2.2. Veri Setinin Özellikleri.....	5
2.3. Veri Setinin Yapısı.....	6
2.4. Veri Setindeki Uçakların Özellikleri.....	6
2.4.1. B-1 uçağı.....	6
2.4.2. B-2 uçağı.....	6
2.4.3. B-52 uçağı.....	7
2.4.4. C-5 uçağı	7
2.4.5. C-130 uçağı	8
2.4.6. C-135 uçağı	8
2.4.7. E-3 uçağı.....	9
2.4.8. KC-10 uçağı	9
2.5. Veri Setinin Daha Önceki Uygulaması	10

3. METOT.....	11
3.1. Veri Setinin Hazırlanması ve Ön İşlem Adımları.....	11
3.1.1. Veri setindeki görsellerin etiketlenmesi	12
3.1.2. Eğitim, doğrulama ve test setine bölme işlemi.....	12
3.1.3. Veri artırma yönteminin uygulanması.....	13
3.2. CNN (Convolutional Neural Network) Modeli	13
3.3. Özellik Çıkarımı ve SVM Modeli.....	15
3.4. Modellerde Kullanılan Algoritmalar	17
3.4.1. Modellerin eğitiminde kullanılan SGDM algoritması	17
3.4.2. Modellerin eğitiminde kullanılan ADAM algoritması.....	19
3.4.3. Modellerin eğitiminde kullanılan RMSPROP algoritması	20
3.5. Karışıklık Matrisi ve Eğitim Grafiklerinin Değerlendirilmesi.....	20
4. DENEYSEL SONUÇLAR.....	22
4.1. CNN Modelinin Değerlendirilmesi.....	22
4.1.1. CNN modelinin eğitiminde SGDM algoritmasının kullanılması.....	22
4.1.2. CNN modelinin eğitiminde Adam algoritmasının kullanılması	24
4.1.3. CNN modelinin eğitiminde RMSprop algoritmasının kullanılması.....	26
4.1.4. CNN modelinde elde edilen en yüksek test doğruluğunun analizi	28
4.2. Veri Artırma İşlemi Uygulanan CNN Modelinin Değerlendirilmesi.....	30
4.2.1. Veri artırma işlemi uygulanan CNN modelinin eğitiminde SGDM algoritmasının kullanılması.....	30
4.2.2. Veri artırma işlemi uygulanan CNN modelinin eğitiminde Adam algoritmasının kullanılması.....	32
4.2.3. Veri artırma işlemi uygulanan CNN modelinin eğitiminde RMSprop algoritmasının kullanılması.....	34
4.2.4. Veri artırma işlemi uygulanmış CNN modelinde elde edilen en	

yüksek test doğruluğunun analizi	36
4.3. CNN-SVM Modelinin Değerlendirilmesi	38
4.3.1. CNN-SVM modelinin eğitiminde SGDM algoritmasının kullanılması.....	38
4.3.2. CNN-SVM modelinin eğitiminde Adam algoritmasının kullanılması.....	40
4.3.3. CNN-SVM modelinin eğitiminde RMSprop algoritmasının kullanılması.....	42
4.3.4. CNN-SVM modelinde elde edilen en yüksek test doğruluğunun analizi	44
4.4. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Değerlendirilmesi 46	
4.4.1. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde SGDM algoritmasının kullanılması.....	46
4.4.2. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde Adam algoritmasının kullanılması	48
4.4.3. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde RMSprop algoritmasının kullanılması.....	50
4.4.4. Veri artırma işlemi uygulanmış CNN-SVM modelinde elde edilen en yüksek test doğruluğunun analizi.....	51
5. SONUÇ VE GELECEKTEKİ ÇALIŞMALAR	54
KAYNAKLAR	58

TABLÖLAR LİSTESİ

Sayfa

Tablo 2.1. Uçak Tipleri ve Görsel Sayıları	5
Tablo 4.1. CNN Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	23
Tablo 4.2. CNN Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	25
Tablo 4.3. CNN Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	27
Tablo 4.4. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	31
Tablo 4.5. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	33
Tablo 4.6. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	35
Tablo 4.7. CNN-SVM Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	39
Tablo 4.8. CNN-SVM Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu.....	41
Tablo 4.9. CNN-SVM Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu	43
Tablo 4.10. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu	47
Tablo 4.11. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu	49
Tablo 4.12. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu	50
Tablo 5.1. Uçak Sınıflarının Kullanılan Modellere Göre Doğrulama Oranları.....	55
Tablo 5.2. Uçak Sınıflarının Modellere Göre Doğru Sınıflandırma Sayıları	55

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1 Wilbur ve Orville Wright kardeşler'in Tasarladığı bir Uçak Modeli	1
Şekil 2.1 B-1 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler	6
Şekil 2.2 B-2 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler	7
Şekil 2.3 B-52 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler	7
Şekil 2.4 C-5 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler	8
Şekil 2.5 C-130 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler	8
Şekil 2.6 C-135 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler	9
Şekil 2.7 E-3 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler	9
Şekil 2.8 KC-10 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler	10
Şekil 3.1 Modelde Kullanılan CNN Mimarisi	14
Şekil 3.2 CNN Modeline Ait Akış Şeması	15
Şekil 3.3 CNN-SVM Modeli Akış Şeması	16
Şekil 4.1 CNN Modelinin En Yüksek Test Doğruluğına Ait Eğitim Grafiğı	29
Şekil 4.2 CNN Modelinin En Yüksek Test Doğruluğına Ait Karışıklık Matrisi	30
Şekil 4.3 Veri Arttırma İşlemi Uygulanmış CNN Modelinin En Yüksek Test Doğruluğına Ait Eğitim Grafiğı	36
Şekil 4.4 Veri Arttırma İşlemi Uygulanmış CNN Modelinin En Yüksek Test Doğruluğına Ait Karışıklık Matrisi	37
Şekil 4.5 CNN-SVM Modelinin En Yüksek Test Doğruluğına Ait Eğitim Grafiğı	45
Şekil 4.6 CNN-SVM Modelinin En Yüksek Test Doğruluğına Ait Karışıklık Matrisi	46
Şekil 4.7 Veri Arttırma İşlemi Uygulanmış CNN-SVM Modelinin En Yüksek Test Doğruluğına Ait Eğitim Grafiğı	52
Şekil 4.8 Veri Arttırma İşlemi Uygulanmış CNN-SVM Modelinin En Yüksek Test Doğruluğına Ait Karışıklık Matrisi	53

SİMGELER VE KISALTMALAR LİSTESİ

α	Momentum Parametresi
β	Momentlerin Üstel Azalma Oranı
B	Hiper Düzlemin Orijinden Uzaklığını Belirten Sabit Değer
C	Düzenleştirme Parametresi
d_H	Hamming Mesafesi
g	Gradyan
$J(\theta)$	Kayıp Fonksiyonu
m_k	ECOC matrisindeki k. sınıfa ait kod vektör
$\hat{m}$	İkili Sınıflandırıcıların Test Verisine İlişkin Tahminlerinden Oluşturulan Kod Vektör
m_t	Birinci moment
s	Gradyan karesinin ortalaması
v	Hız
v_t	İkinci moment
$\theta^{(k)}$	Ağırlıklar
ξ	Hata Payı
γ	Gradyan karesi değerlerinin hareketli ortalamadaki ağırlığı
ϵ	Öğrenme oranı
W	Hiper Düzlemi Tanımlayan Ağırlık Vektörü
ADAM	Uyarlamalı Moment Tahmini
ANN	Yapay Sinir Ağı
AWACS	Havadan İhbar ve Kontrol Sistemi
CNN	Evrişimli Sinir Ağı
CRFs	Koşullu Rastgele Alanlar
ECOC	Hata Düzeltici Çıkış Kodları
FC	Tam Bağlantılı
GAN	Üretici Çekişmeli Ağlar
JPEG	Birleşik Fotoğraf Uzmanları Grubu
LDA	Gizli Dirichlet Dağılımı
MTARSI	Uzaktan Algılama Görüntülerindeki Farklı Türdeki Uçaklar
PNG	Taşınabilir Ağ Grafikleri
RMSProp	Karekök Ortalama Yayılımı

SGDM	Momentumlu Stokastik Gradyan İnişı
SVM	Destek Vektör Makinesi



1. GİRİŞ

Uçakların insan hayatına girmesi, ulaşım, taşımacılık ve askeri alanların gelişmesinde büyük bir rol oynamıştır ve bu alanlarda önemli ilerlemeler kaydedilmiştir. Havacılık tarihindeki en önemli kilometre taşlarından biri, Wright Kardeşler 'in 1903'te yaptığı ilk motorlu uçuş olmuştur. Bu başarı, insanların gökyüzünde uçuş hayalini gerçeğe dönüştürerek modern havacılığın temelini atmıştır [1].



Şekil 1.1 Wilbur ve Orville Wright kardeşler'in Tasarladığı bir Uçak Modeli

Wilbur ve Orville Wright kardeşler 17 Aralık 1903'te iki pervaneli, pilotla beraber ağırlığı toplam 335 kg olan uçak ile ilk denemelerinde 12 saniye havada kalmış ve toplam 37 metre mesafe ileri gidebilmişlerdir. O gün yaptıkları son denemede ise 59 saniye havada kalmış ve 260 metrelik bir mesafe katetmişlerdir.

Teknolojinin ilerlemesiyle birlikte birçok amaca uygun uçak türü geliştirilmiştir. Artık uçaklar tonlarca ağırlığı taşıyabilmekte ve saatlerce havada kalabilmektedir. Bunların yanı sıra artık uçaklar güvenlik açısından da ülkeler için önem arz etmektedir. Uçak türlerinin sınıflandırılması havacılık, savunma, lojistik ve birçok farklı endüstride kritik bir öneme sahiptir. Uçakların doğru tespiti, havacılık güvenliği açısından kritik bir unsurdur. Özellikle hava sahasında farklı uçakların doğru tanımlanması ve izlenmesi, çarpışma önleyici sistemler ve hava trafik kontrolü için büyük bir öneme sahiptir. Görüntü tabanlı sınıflandırma sistemleri, uçuş güvenliğini artırarak, yanlış tanımlama kaynaklı kazaları önlemektedir. Acil durumlarda müdahale için uçakların hızlı ve doğru bir şekilde tanımlanması gerekir. Görüntüler üzerinden hızlı sınıflandırma, acil müdahale ekiplerinin

doğru ekipman ve strateji ile harekete geçmesine olanak tanır. Uçakların görsellerle tespiti, askeri savunma sistemleri için stratejik bir rol üstlenir. Radar sistemleri ya da görsel izleme sistemleri, düşman uçaklarını veya tehdit oluşturabilecek unsurları tespit etmek için uçak türlerinin hızlı ve doğru bir şekilde sınıflandırılmasına dayanır. Bu sayede, dost-düşman ayrımı daha güvenilir yapılabilir ve savunma stratejileri daha etkili bir şekilde uygulanabilir. Havaalanlarında veya sınır bölgelerinde uçakların sınıflandırılması, güvenlik önlemlerinin optimize edilmesine yardımcı olur. Şüpheli veya izinsiz uçuş yapan uçakların tespiti, bu sistemler sayesinde hızlandırılabilir. Özellikle gözetleme ve izleme sistemlerinde, uçakların otomatik olarak tanımlanması, geniş alanlarda insan denetimine ihtiyaç duymadan doğru sınıflandırma yapmayı sağlar.

Bu tezde kullanılan veri setinde 8 farklı askeri uçak tipi derin öğrenme ve geleneksel sınıflandırma yöntemleri ile incelenmiştir. Sınıflandırma açısından doğruluk oranları karşılaştırılmıştır. Toplamda 4990 adet görsel sınıflandırma için kullanılmış olup, uçak başına ortalama 600-680 adet görselden yararlanılmıştır. İlk aşamada bütün veri seti işlenmeden yani herhangi bir görüntü işleme ya da farklı bir müdahale olmadan doğrudan CNN modeline uygulanmıştır. CNN uygulanırken “InitialLearningRate”, “trainingOptions” ve “Epoch” değerleri değiştirilerek karşılaştırmalar yapılmıştır. Daha sonrasında CNN ve SVM birlikte kullanılmıştır. CNN’de elde edilen Özellik Haritaları (FeatureMaps) doğrudan SVM’ye verilerek doğrulama doğruluğu ve test doğruluğu oranları analiz edilmiştir. Son aşamada ise kullanılan modellere veri artırma yöntemleri de eklenerek doğrulama doğruluğu ve test doğruluğu oranlarında artış gözlemlenmiştir.

1.1. Literatürdeki Çalışmalar

Uçak tanıma ve sınıflandırma alanında gerçekleştirilen çalışmalar ile yüksek çözünürlüklü uydu görüntüleri ve gelişmiş makine öğrenimi yöntemleri kullanılarak önemli ilerlemeler kaydedilmiştir. Bu kapsamda, 2015 yılında Qichang Wu, Hao Sun, Xian Sun, Daobing Zhang, Kun Fu ve Hongqi Wang tarafından gerçekleştirilen bir çalışmada, 7 farklı uçak türüne ait toplam 80 yüksek çözünürlüklü havaalanı görüntüsü kullanılarak uçak sınıflandırması yapılmıştır. Çalışma, her uçak türü için 30 görüntüden oluşan bir veri seti üzerinde, gradyan değerlerini hesaplayarak kontur ve doku bilgilerini elde etmiş ve görüntü parlaklığındaki değişimlerden kaynaklanan parazitleri azaltmayı amaçlamıştır. Görüntülerin histogramları analiz edilerek uçak gövdesinin yönü belirlenmiş ve “Jigsaw Matching Pursuit Algorithm” adı verilen bir yöntemle %92,9 test doğruluk oranına ulaşılmıştır. Bu çalışma, uçak sınıflandırma alanında dikkate değer bir başlangıç noktası oluşturmuştur [2].

2017 yılında An Zhao, Kun Fu, Siyue Wang, Jiawei Zuo, Yuhang Zhang, Yanfeng Hu ve Hongqi Wang tarafından yapılan bir diğer çalışma ise, 11 farklı uçak türüne ait toplam 9594 kırpılmış uçak görüntüsünden oluşan bir veri seti ile gerçekleştirilmiştir. Çalışmada, uçak sınıflandırma problemi, işaret noktası tespit problemine dönüştürülmüş ve “Vanilla CNN” adı verilen bir CNN varyantı kullanılmıştır. Her bir uçak görüntüsü üzerinde saat yönünün tersine sıralanan sekiz anahtar noktadan uzunluk, genişlik ve diğer boyutsal bilgilerin çıkarılması sağlanmıştır. Bu yöntemle %93,6 test doğruluk oranına ulaşılmıştır [3].

2018 yılında Yuhang Zhang, Hao Sun, Jiawei Zuo, Hongqi Wang, Guangluan Xu ve Xian Sun tarafından önerilen bir çalışma, Generative Adversarial Networks (GAN) ve SVM tabanlı bir yaklaşım kullanarak sınırlı sayıda etiketli veri ile uçak sınıflandırması gerçekleştirmiştir. Çalışmada, Google Earth üzerinden elde edilen 16393x16393 piksel çözünürlüğe sahip optik uydu görüntülerinden 8 anahtar nokta belirlenmiş ve bu noktalar üzerinden özellik çıkarımı yapılmıştır. Bu yöntem, AlexNet, VGG-16 ve ResNet-18 gibi popüler CNN modelleriyle karşılaştırılmış ve %92,73 test doğruluk oranı ile başarılı bir sonuç elde edilmiştir [4].

Aynı yıl Jiawei Zuo, Guangluan Xu, Kun Fu, Xian Sun ve Hao Sun, uçak sınıflandırma alanında segmentasyon tabanlı bir yaklaşım önererek bir evrişimli kodlayıcı-çözücü ağ geliştirmiş ve segmentasyon sonuçlarını hassaslaştırmak için Conditional Random Fields (CRF) uygulamıştır. Ayrıca, uçak yönü tahmini için anahtar nokta tespiti görevine odaklanılmış ve çoklu döndürme iyileştirme yöntemi ile sonuçlar daha da geliştirilmiştir. 0,6 metre çözünürlükte Quickbird uydu görüntülerinden elde edilen 13000 adet görsel üzerinde yapılan bu çalışmada %95,6 test doğruluk oranı elde edilmiştir [5].

Diğer bir çalışmada, Faisal Azam ve arkadaşları, Military Tactical Aerial Reconnaissance and Surveillance Images (MTARSI) veri setini kullanarak 36 farklı havaalanından elde edilen görüntülerle 20 uçak türünü sınıflandırmış ve en yüksek test doğruluk oranını %96,8 ile Lineer SVM yöntemi kullanarak elde etmişlerdir [6].

2020 yılında gerçekleştirilen bir başka çalışmada, Vision Transformers, ResNet50v2, EfficientNetB0 ve InceptionNetV3 gibi modern derin öğrenme mimarileri kullanılarak transfer öğrenme yöntemlerinin etkisi incelenmiştir. Bu çalışmalar, %95'e varan test doğruluk oranlarıyla transfer öğrenmenin uçak sınıflandırma alanındaki etkinliğini kanıtlamış ve bu alanda gelecekteki araştırmalara yön verecek bir temel oluşturmuştur [7].

Son olarak, ticari hava araçlarının sınıflandırılmasına yönelik bir çalışmada Boeing 737-800, Airbus A319, Airbus A320 ve Boeing 777 gibi uçak türlerinin görüntüleri üzerinde Sobel operatörü ile kenar tespiti yapılmıştır. Bu tespitler üzerinden Linear Discriminant

Analysis (LDA) ve SVM algoritmaları kullanılarak %91 test doğruluk oranına ulaşılmıştır [8].

Tüm bu çalışmalar, uçak sınıflandırma alanında kullanılan yöntemlerin ve veri setlerinin çeşitliliğini göstermektedir. Her birinin elde ettiği test doğruluk oranları, önerilen yöntemlerin etkinliğini ortaya koymaktadır. Uçak sınıflandırma alanındaki yenilikçi yaklaşımlar, derin öğrenme algoritmalarının etkisini vurgulamakta ve bu teknolojilerin askeri, ticari ve bilimsel alanlardaki uygulama potansiyelini göstermektedir.



2. MATERYAL

Çalışmanın bu bölümünde, kullanılan veri setine ait genel bilgiler verilmektedir. İlgili veri setinin özellikleri, içeriği ve daha önceki uygulaması detaylı bir şekilde ele alınmıştır.

2.1. Veri Setine İlişkin Genel Bilgilendirme

Bu araştırmada kullanılacak uçak görüntüleri Shayan Khaos tarafından oluşturulan veri setinden alınmıştır. Kendi çalışması dışında herhangi bir makalede bu veri setinin kullanıldığına rastlanmamıştır. 9 farklı uçak tipini içeren bu veri seti, farklı havaalanlarından alınan Google Haritalar (Google Maps) görüntülerini içermektedir. Hava üslerinin beton asfaltı veya dünya genelindeki bazı açık hava uçak depolama alanları gibi çeşitli arka planlar için de görseller toplanmıştır. Toplamda 6300 görüntüden oluşan bu veri kümesinde, görüntülerin boyutları farklılık göstermektedir. Her uçak türü için yaklaşık 610 - 660 arası görüntü bulunmaktadır [9]. Paylaşılan dosyada verilen uçak türlerinden “C-17” uçağı veri seti dosyasında birebir aynı görselleri içerdiğinden, sonuçları etkilememesi adına çalışmaya dahil edilmemiştir. Doğrudan uçaklar üzerinden sınıflandırma yapılabilmesi için arka plan görüntüleri uygulamalarda kullanılmamıştır. Toplamda ise 4990 adet uçak görseli kullanılmıştır.

2.2. Veri Setinin Özellikleri

8 farklı uçak türünü içeren bu veri setinde, uçak tiplerine ait görsel sayıları Tablo 2.1.’de verilmiştir.

Tablo 2.1. Uçak Tipleri ve Görsel Sayıları

Uçak Tipi	Görsel Sayısı
B-1	620
B-2	663
B-52	607
C-5	616
C-130	632
C-135	616
E-3	626
KC-10	638

Her bir uçak görselini içeren kümelerde farklı büyüklüklerde, farklı arka planlara ve farklı uçak renklerine sahip görseller mevcuttur. Veri setindeki görüntüler “.jpg”, “.jpeg” ve “.png” uzantılarıyla verilmiştir.

2.3. Veri Setinin Yapısı

Shayan Khaos tarafından Google Haritalar (Google Maps) görüntüleri ile hazırlanan bu veri setinde kullanılan 4990 adet görselin:

- %70'i eğitim,
- %15'i test,
- %15'i doğrulama için kullanılmıştır.

Bu görsellerin sınıflandırılması için çalıştırılan kodlar, 4990 adet görsel rastgele olacak şekilde eğitim, test ve doğrulama kümesinde kullanılmıştır.

2.4. Veri Setindeki Uçakların Özellikleri

Bu çalışmada kullanılan uçaklara ait birbirinden farklı görseller ve uçakların özellikleri, ilgili uçakların başlıklarının altında verilmiştir.

2.4.1. B-1 uçağı

B-1 uçağı, 1986 yılında hizmete giren Amerika Birleşik Devletleri (ABD) değişken kanatlı stratejik bombardıman uçağıdır. B-1 uçağının uzunluğu 44,8 metre olup, kanatlarının tamamen açık olduğu durumda yaklaşık 42 metre açıklığa sahiptir [10]. B-1 uçağına ait görseller Şekil 2.1'de verilmiştir.



Şekil 2.1 B-1 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler

2.4.2. B-2 uçağı

Northrop Grumman B-2 Spirit veya bilinen adıyla Gizli Bombardıman Uçağı,

yoğun uçaksavar savunmalarını engellemek için tasarlanan bir Amerikan ağır stratejik bombardıman uçağıdır. İki kişilik mürettebatı olan, süpersonik olmayan ve uçan kanat tasarımına sahip bu uçağın üretimi 1987'den 2000'e kadar devam etmiştir. B-2 uçağının uzunluğu 21 metre ve kanat açıklığı yaklaşık 52 metredir [11]. B-2 uçağına ait görseller Şekil 2.2'de verilmiştir.



Şekil 2.2 B-2 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler

2.4.3. B-52 uçağı

B-52, Boeing Şirketi tarafından 1948'de tasarlanan, ilk uçuşu 1952'de yapılan ve ilk kez 1955'te askeri hizmete sunulan ABD uzun menzilli ağır bombardıman uçağıdır. Başlangıçta Sovyetler Birliği'ne ulaşabilen bir atom bombası taşıyıcısı olarak tasarlanmış olsa da çok sayıda göreve uyarlanabilir olduğunu kanıtlamıştır. B-52 uçağının uzunluğu 49 metre ve kanat açıklığı 56 metreden oluşmaktadır [12]. B-52 uçağına ait görseller Şekil 2.3'te verilmiştir.



Şekil 2.3 B-52 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler

2.4.4. C-5 uçağı

Lockheed C-5 Galaxy, Lockheed tarafından tasarlanıp inşa edilen, bakımı ve yükseltmesi yapılan büyük bir askeri nakliye uçağıdır. Amerika Birleşik Devletleri Hava Kuvvetleri'ne (USAF) tüm hava sertifikalı kargolar dahil olmak üzere, büyük yükleri taşıyabilen, kıtalararası menzilli stratejik nakliye uçağıdır. C-5 uçağı, dünyanın en

büyük askeri uçakları arasında yer almaktadır. Uzunluğu 75 metre ve kanat açıklığı 68 metredir [13]. C-5 uçağına ait görseller Şekil 2.4'te verilmiştir.



Şekil 2.4 C-5 Uçağına Ait Veri setinde Kullanılan Görsellere Örnekler

2.4.5. C-130 uçağı

C-130 Hercules, Amerikalı Lockheed (şu an Lockheed Martin) firması tarafından geliştirilen orta sınıf bir taktik nakliye uçağıdır. Havacılık tarihinin en başarılı nakliye uçaklarından biri olarak kabul edilmektedir. Bugüne kadar, 2500'den fazla C-130, dünya çapında 63 ülkeye sipariş edilmiştir. Yetmiş ülke, 70'ten fazla farklı varyantta üretilen C-130 uçaklarını kullanmaktadır. Yaklaşık 30 metre uzunluğunda ve yaklaşık 40 metre kanat genişliğindedir [14]. C-130 uçağına ait görseller Şekil 2.5'te verilmiştir.



Şekil 2.5 C-130 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler

2.4.6. C-135 uçağı

C-135 uçağı, Boeing firması tarafından üretilen ve havada diğer uçaklara ikmal yapılması için kullanılan bir uçaktır. Uzunluğu yaklaşık 42 metre ve kanat açıklığı 13 metredir [15]. C-135 uçağına ait görseller Şekil 2.6'da verilmiştir.



Şekil 2.6 C-135 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler

2.4.7. E-3 uçağı

E-3 uçağı, havadan erken uyarı ve kontrol sistemi (AWACS), Boeing Defense & Space Group tarafından üretilmiştir. E-3 uçağının rolü, hava savunma güçleri için havadan gözetim yapmak ve komuta, kontrol, iletişim (C3) işlevlerini yerine getirmektir [16]. Uzunluğu yaklaşık 47 metre ve kanat açıklığı 44,5 metredir [17]. E-3 uçağına ait görseller Şekil 2.7’de verilmiştir.



Şekil 2.7 E-3 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler

2.4.8. KC-10 uçağı

KC-10 uçağı, ABD silahlı kuvvetlerine küresel hareket kabiliyeti sağlamak amacıyla tasarlanmış, gelişmiş bir tanker ve kargo uçağıdır. KC-10 uçağının birincil görevi havadan yakıt ikmali olsa da tanker ve kargo uçağı görevlerini birleştirerek savaş uçaklarına yakıt ikmali yapabilir niteliktedir. Aynı zamanda deniz aşırı görevlere savaş uçağı destek personeli ve ekipman taşıyabilmektedir. Uzunluğu yaklaşık 54,5 metre ve kanat açıklığı 50 metredir [18]. KC-10 uçağına ait görseller Şekil 2.8’de verilmiştir.



Şekil 2.8 KC-10 Uçağına Ait Veri Setinde Kullanılan Görsellere Örnekler

2.5. Veri Setinin Daha Önceki Uygulaması

Shayan Khos'un oluşturduğu bu veri seti ile kendisi de CNN kullanarak bir sınıflandırma işlemi gerçekleştirilmiştir. Model tasarımında, küçük veri setinin ve çapraz doğrulama kaybının minimize edilmesi gereksinimi iki temel unsur olarak ele alınmıştır. Küçük veri seti boyutları nedeniyle aşırı öğrenmeyi önlemek için daha az karmaşık bir model tercih edilmiştir. Geliştirilen CNN modeli, Keras'ın sağladığı hiper parametre ayarlama fonksiyonu kullanılarak optimize edilmiş ve en yüksek çapraz doğrulama doğruluğu ile en düşük çapraz doğrulama kaybına ulaşılmıştır. Model, 0.0001 öğrenme oranı ile adam optimize edici (optimizer) kullanılarak ve seyrek kategorik çapraz entropi kaybı yöntemiyle derlenmiştir. Model, 30 epok boyunca ve yığın boyutu (batch size) 64 olarak eğitilmiştir. Modelin elde ettiği en yüksek çapraz doğrulama doğruluğu yaklaşık %91, ulaşılan en düşük çapraz doğrulama doğruluğu ise yaklaşık %33,22'dir. Eğitim doğruluğu yaklaşık %98, eğitim kaybı ise 0,0610 olarak kaydedilmiştir. Bu çalışmanın en önemli sonuçlarından biri, veri setinin kalitesinin modelin performansı üzerindeki kritik etkisidir. %91 gibi yüksek bir çapraz doğrulama doğruluğuna ulaşılmıştır.

3. METOT

Bu çalışmada, farklı uçak türlerini sınıflandırmaya yönelik olarak derin öğrenme ve geleneksel makine öğrenmesi yöntemleri kullanılmıştır. Aynı zamanda görsellerin yeniden boyutlandırılması ve veri artırma gibi klasik görüntü işleme adımlarını da içeren çok yönlü bir yaklaşım sunulmuştur. Bu bölümün devamındaki alt başlıklarda bu sınıflandırma yöntemleri detaylı bir şekilde açıklanmıştır.

3.1. Veri Setinin Hazırlanması ve Ön İşlem Adımları

Veri hazırlığı aşamasında, her uçak türü için farklı klasörler kullanılmış ve bu klasörlerde bulunan tüm görüntülerin yolları ayrı olarak tanımlanmıştır. Hiper parametreler değiştirilerek farklı modellerin veri seti üzerindeki doğrulama doğruluğu ve test doğruluğu oranları değerlendirilmiştir. Bu çalışmada değişkenlik gösteren hiper parametreler, öğrenme oranı, epok sayısı ve optimize edici algoritma yapısıdır. Mini yığın boyutu (mini-batch size), verilerin her epokta karıştırılıp karıştırılmaması (shuffle) ve eğitim sırasında kaç mini yığının doğrulama işlemi yapacağı gibi hiper parametreler sabit tutulmuş; bu ayarlar çalışmada kullanılan her modelde aynı şekilde uygulanmıştır. Mini yığın boyutu 128 olarak ayarlanmıştır. Değiştirilen hiper parametreler ile her biri çalışma içerisindeki farklı bir kısımda modellerin test ve doğrulama doğruluğu oranlarını değiştirmesi beklenmiştir. Epok, eğitim verisinin model tarafından bir kez işlenmesidir. Epok sayısı, modelin eğitim verisini kaç kez baştan sona göreceğini ve bu veriler üzerinden öğrenme sürecini kaç kez gerçekleştireceğini belirlemek amacıyla kullanılan bir hiper parametredir. Epok hiper parametresi öğrenme sürecini optimize etmek için kullanılmaktadır. Epok sayısının yüksek olması modelin süresini artırır. Bu modellerde kullanılan bir başka hiper parametre başlangıç öğrenme oranıdır. Başlangıç öğrenme oranı, modelin eğitimi sırasında ağırlıkların ne kadar büyük adımlarla güncelleneceğini belirleyen araçtır. Çok düşük olduğunda öğrenme aşırı yavaş olur ve eğitim uzun sürer. Modelin öğrenme hızını ve doğruluk oranını optimize etmektedir. Modelleri optimize etmek amacıyla 3 farklı algoritma (sgdm, adam, rmsprop) kullanılmaktadır. Optimize edici olarak kullanılan bu algoritmalar, modeli eğitirken hata fonksiyonunu en aza indirmek için ağırlıkların nasıl güncelleneceğini belirleyen matematiksel yöntemlerdir. Optimize edici algoritmalar, derin öğrenme modellerinde kayıp fonksiyonunu minimize etmek, diğer bir deyişle hata oranını düşürmek için kullanılır.

3.1.1. Veri setindeki görsellerin etiketlenmesi

Bu çalışmada, sınıflandırma doğruluk oranlarını bulmak için kullanılan bütün kodlarda, her bir uçak türü için ayrı bir klasör yolu tanımlanmıştır (dataFolders değişkeni). Her bir klasörün ismi, ilgili klasörde bulunan görüntülerin etiketini belirtir. Örneğin, 'C:\Users\CP\Desktop\tamset\B-1' klasöründe bulunan tüm dosyalar "B-1" etiketiyle etiketlenmiştir.

- Klasör yollarından toplanan görüntü dosyaları listelenir (fileList değişkeni), tam yolları (imageFiles değişkeni) ve klasör isimlerinden elde edilen etiketler (imageLabels değişkeni) oluşturulur.
- "imageFiles" değişkeni tanımlanırken "fullfile" fonksiyonu kullanılmaktadır. Bu fonksiyon, belirtilen klasör ve dosya adlarından tam bir dosya yolu oluşturmaktadır [19].
- "imageLabels" değişkeni tanımlanırken dosya adlarının etiket olarak kullanabilmek için "categorical" fonksiyonu kullanılır. Çıktı dizisinin kategorileri, giriş dizisindeki benzersiz ve sıralanmış değerlerden oluşmaktadır [20].
- "imageDatastore" nesnesi (imds), görüntü dosyalarını ve etiketleri saklar. Bu nesne, görüntülerin kategorik etiketlerini klasör isimlerine göre otomatik olarak belirlemektedir. İlgili konumdaki görüntü verilerinden oluşan bir datastore (veri deposu) nesnesi olan imds'yi oluşturur [21]. Örneğin, "C:\Users\CP\Desktop\tamset\B-1" klasöründeki tüm görüntüler, "B-1" olarak etiketlenmiştir.

3.1.2. Eğitim, doğrulama ve test setine bölme işlemi

"splitEachLabel" fonksiyonu ile "imds" nesnesi eğitim, doğrulama ve test setlerine ayrılır. "imageDataStore" ile elde ettiğimiz veri depomuz (imds) "splitEachLabel" ile ilk olarak rastgele bir şekilde %70'ini eğitim seti olarak atar, kalanını ise test ve doğrulama olarak kullanılmaktadır [22]. Geriye kalan verinin %30'unu rastgele bir şekilde tekrar yarıya bölerek doğrulama ve test setlerini oluşturmaktadır. Bu ayırım sonunda, her klasördeki görüntülerin %70'i eğitim, kalan %15'i doğrulama ve %15'i test setine atanmaktadır.

- Model, "augimdsTrain" eğitim verileri kullanılarak eğitilir ve her görüntünün etiketine (örneğin "B-1", "C-130") göre sınıflandırma yapmayı öğretmektedir. "augimdsTrain" değişkeni için "augmentedImageDatastore" fonksiyonu kullanılır. Bu fonksiyon eğitim, doğrulama, test ve tahmin verisi gruplarını dönüştürmek için kullanılmaktadır. Bu dönüşüm sürecinde, yeniden boyutlandırma işlemi uygulanmıştır [23]. Bu işlem bütün modellerde kullanılmıştır. CNN yöntemi kullanılan algorithmada "classify"

fonksiyonu ile test setindeki görüntülerin etiket tahminleri elde edilir ve gerçek etiketlerle karşılaştırılır.

- SVM yöntemi kullanılan algorithmada “predict” fonksiyonu ile eğitilmiş olan SVM modelini CNN’den çıkarılan özellikler ile tahmini yapar. Tahmin edilen sınıflar ile gerçek sınıflar karşılaştırılarak doğruluk oranını verir.


3.1.3. Veri artırma yönteminin uygulanması

Çalışmada kullanılan modellerde veri artırma yöntemi kullanılarak genelleme kabiliyeti yükseltilmeye çalışılmıştır. Eğitim verilerine uygulanan veri artırma işlemi, “imageDataAugmenter” fonksiyonu ile belirlenen dönüşüm parametreleri ([-10 10] döndürme, [-5 5] piksel yatay/dikey kaydırma ve [0.9 1.1] ölçeklendirme) aracılığıyla sağlanmaktadır. Bu çalışmada kullanılan kodlarda modelin daha genelleyici olması, verilerdeki sapmaların sabit olmaması ve gerçek dünya koşullarına daha yakın olması adına veri artırma işlemi, “imageDataAugmenter” fonksiyonun tüm özellikleri için kullanılan değerler (döndürme, adım büyüklüğü ve kaydırma) rastgele verilmiştir. Bu dönüşümler, “augmentedImageDatastore” fonksiyonu kullanılarak gerçek zamanlı (on-the-fly) uygulanır; orijinal görüntüler değiştirilmeden, her epokta farklı varyasyonlar oluşturmaktadır. Sonuç olarak, model, “trainNetwork” fonksiyonu ile eğitildiğinde, bu zenginleştirilmiş veri sayesinde nesnelerin farklı açılardan, konumlardan ve boyutlardan elde edilen örneklerini öğrenerek aşırı uyum (overfitting) riskini azaltmaktadır.

3.2. CNN (Convolutional Neural Network) Modeli

Bu çalışmada sınıflandırma amacıyla CNN modeli kullanılmıştır. CNN, özellikle görüntü işleme ve sınıflandırma alanlarında yaygın olarak tercih edilen bir derin öğrenme mimarisidir. Karmaşık veri yapılarından etkili bir biçimde öznelik çıkarımı yapabilmektir. CNN, aynı zamanda ConvNet olarak da adlandırılır, bir tür Yapay Sinir Ağı’dır (ANN) ve Tam Bağlantılı katmana (Fully Connected Layer) sahip diğer ağlara kıyasla olağanüstü bir genelleştirme yeteneği göstermektedir. Özellikle uzamsal veriler gibi nesnelerin yüksek derecede soyutlanmış özelliklerini öğrenebilir ve bu nesneleri daha verimli bir şekilde tanımlayabilmektedir. Derin bir CNN modeli, giriş verilerinin çeşitli özelliklerini öğrenebilen ve farklı soyutlama seviyelerinde işleyebilen sınırlı sayıda işlem katmanından oluşur. Başlangıç katmanları yüksek seviyeli özellikleri (daha düşük soyutlama ile) öğrenir ve çıkarır, daha derin katmanlar ise düşük seviyeli özellikleri (daha yüksek soyutlama ile) öğrenir ve çıkarır [24].

Modelde sırasıyla 8, 16 ve 32 filtre boyutlu üç adet Evrişimli Katman (Convolutional Layer) ve her birinin ardından Batch Normalization ve ReLU aktivasyon fonksiyonu eklenmiş, alt örnekleme için Maksimum Havuzlama (Max-Pooling) katmanları kullanılmıştır. Ağın son bölümünde sınıf sayısı kadar nörona sahip Tam Bağlantılı Katman (Fully Connected Layer), ardından Softmax Katmanı kullanılarak çıktı üretilmiştir. CNN'e ait mimari Şekil 3.1'de verilmiştir.




Şekil 3.1 Modelde Kullanılan CNN Mimarisi

Tam bağlantılı katman, verinin son sınıflandırılmasını sağlar ve sınıf sayısına göre düzenler. Çıktı katmanında softmax katmanı tam bağlantılı katmandan gelen sınıf değerlerini alır ve bu değerleri olasılıklara dönüştürür. “classificationLayer”, softmax katmanından aldığı verileri ve etiketleri karşılaştırır. Kayıp değerini hesaplayarak ağırlıkların güncellenmesi için geri yayılım sürecinde kullanır. Bu ağırlıklar optimize edici algoritmalarla yapılır. Bu şekilde CNN modelinde sınıflandırma işlemi tamamlanmış olur.

Doğrulama Doğruluğu (Validation Accuracy), CNN eğitimi sırasında doğrulama setini kullanır. Doğrulama doğruluğu, modelin doğrulama setindeki performansını ölçer ve eğitim sırasında aşırı öğrenme (overfitting) olup olmadığını anlamak için kullanılır. Test doğruluğu (Test Accuracy) ise, modelin eğitim süreci tamamlandıktan sonra daha önce hiç görmediği test verileri üzerindeki genel performansı ölçmek amacıyla hesaplanır. Modelin performansı, test doğruluğu ve doğrulama doğruluğu değerleri esas alınarak analiz edilmiştir. CNN'e ait akış şeması Şekil 3.2.'de verilmiştir.

CNN Modeli Akış Şeması




Şekil 3.2 CNN Modeline Ait Akış Şeması

3.3. Özellik Çıkarımı ve SVM Modeli

CNN-SVM modelinde sınıflandırmak amacıyla SVM kullanılmıştır. CNN modelinin relu_3 katmanı özellik çıkarımı için kullanılmıştır. Relu_3 katmanı, sınıflandırma için önemli olan görsel özellikleri yakalayan ara bir katman olarak belirlenmiştir. SVM'in sınıflandırması için relu_3 katmanından elde edilen aktivasyon değerleri, "özellik vektörü" şeklinde kaydedilmiştir ve bu katmandan elde edilen aktivasyon değerleri SVM modeline aktarılmıştır. SVM modeli, çok sınıflı sınıflandırmayı gerçekleştirmek için fitcecoc fonksiyonu ile eğitilmiş ve test seti üzerinde değerlendirilmiştir. SVM, veri noktaları arasındaki en geniş marjı bularak iki sınıfı ayırma ilkesine dayanan, ancak aynı zamanda çekirdek (kernel) fonksiyonları sayesinde doğrusal olmayan örüntüleri de yüksek boyutlu uzaylarda tespit edebilen bir yöntem olarak tanımlanmaktadır [28]. Doğrusal olmayan veri kümeleri için çekirdek yöntemi adı verilen bir prosedürle, RBF (Radial Basis Function) veya polynomial gibi çekirdek fonksiyonları kullanılarak veri yüksek boyutlu uzaylarda temsil

edilirmiş gibi işlenir; böylece ayırt edici desenlerin daha kolay yakalanabilmesini sağlamaktadır. SVM'in yapısal risk minimizasyonu temelli yaklaşımının, veri üzerinde hem marjı maksimize etme hem de karmaşıklığı kontrol etme yoluyla etkili bir sınıflandırma sağladığını öne çıkararak, SVM'in performansının doğru kernel seçimi ve düzenleme (regularization) parametrelerine büyük ölçüde bağlı olduğunu belirtmektedir [29]. CNN-SVM modeline ait akış şeması Şekil 3.3'te verilmiştir.



Şekil 3.3 CNN-SVM Modeli Akış Şeması

Tezde kullanılan SVM modeli çok sınıflı (multiclass) sınıflandırma için Error-Correcting Output Codes (ECOC) yöntemi ile lineer çekirdekli modeli kullanılmıştır. ECOC, birden fazla ikili (binary) sınıflandırıcıyı birlikte kullanarak çok sınıflı

sınıflandırmayı gerçekleştirir. Her bir sınıf çifti veya sınıf kümeleri için ayrı ayrı SVM sınıflandırıcıları eğitilir. Bu çalışmada kullanılan Matlab'ın “fitcecoc” fonksiyonu varsayılan olarak, bire karşı bir stratejisini kullanmaktadır.

Her ikili SVM sınıflandırıcısı belirli kısıtlar altında, 3.14'teki optimizasyon problemini çözer:

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, 2, 3, \dots, N \quad (3.14)$$

$$\min_{w, b, \xi_i} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (3.15)$$

Formüllerde verilen, “x” eğitim verilerinden çıkarılan CNN tabanlı öznitelik vektörleri, “y” örneklerin sınıf etiketlerini temsil eder (ikili durumda +1 veya -1). Çok sınıflı sınıflandırma durumunda ise, bir test verisinin ait olduğu sınıfı belirlemek için tüm ikili sınıflandırıcılardan elde edilen sonuçlar ECOC matrisi üzerinde kodlanır. Bu ECOC matrisi M boyutu K x L olan (K: sınıf sayısı, L: ikili sınıflandırıcı sayısı) bir matristir. Test verisi için her sınıflandırıcının tahmini sonuçları vektör halinde toplanarak bir tahmin kodu oluşturulur. Tahmin edilen sınıf, bu tahmin koduna en yakın kodu veren sınıf olarak belirlenir. Bu yakınlık genellikle Hamming mesafesi ile hesaplanır:

$$\hat{y} = \arg \min_{k=1, \dots, K} d_H(m_k, \widehat{m}) \quad (3.16)$$

CNN ile çıkarılan derin öğrenme özellikleri kullanılarak ECOC tabanlı SVM sınıflandırması ile uçak türlerinin sınıflandırılması gerçekleştirilmiştir.

3.4. Modellerde Kullanılan Algoritmalar

CNN ve CNN-SVM modellerinde üç farklı algoritma (sgdm, adam ve rmsprop) kullanılmıştır. Kullanılan bu algoritmalar modellerin öğrenilebilir parametrelerini güncelleyerek kayıp fonksiyonunu minimize etmeyi amaçlayan matematiksel yöntemlere dayanmaktadır.

3.4.1. Modellerin eğitiminde kullanılan SGDM algoritması

SGDM algoritması, klasik stokastik gradyan inişi (SGD) yönteminin, yakınsama hızını artırmakla kalmaz, aynı zamanda yerel minimumlara daha etkin bir şekilde ulaşmayı sağlamaktadır ve bu süreçte “Poisson” gibi gürültülerin etkisini azaltarak daha kararlı

sonular retmektedir. Bu yntem, nceki iterasyonlardan elde edilen gradyan bilgisini de kullanarak gncelleme yapar, bylece daha kararlı ve hızlı bir yakınsama saėlamaktadır.

Klasik SGD, parametre gncellemesini aėaėıdaki řekilde gerekleřtirir:

$$\theta_{t+1} = \theta_t - \alpha g_t \quad (3.1)$$

nceki iterasyonlarda biriken gradyan bilgisi, momentum vektr v_t aracılıėıyla gncelleme adına dahil edilerek SGDM algoritması oluřturulur. $v_0 = 0$ Olarak kabul edilir:

$$v_t = \mu v_{t-1} + g_t \quad (3.2)$$

nceki iterasyonların etkisini μ katsayısı ile biriktirerek, gradyanın grltl yapısının yarattıėı dalgalanmaları azaltır. Momentum vektrnn hesaplanmasının ardından, model parametreleri aėaėıdaki gncelleme kuralı ile yeniden ayarlanır:

$$\theta_{t+1} = \theta_t - \alpha v_t \quad (3.3)$$

g_t Tm veri kmesi yerine, her iterasyonda seilen m rnekten oluřan mini-batch zerinden hesaplanır:

$$g_t = \frac{1}{m} \sum_{i=1}^m \nabla_{\theta} J(\theta_t; x_i, y_i) \quad (3.4)$$

Burada (x_i, y_i) mini bir yıėın iindeki i'inci rneėi temsil eder. Bařlangıta $v_0 = 0$ ve θ_t uygun bir řekilde bařlatılır ve her iterasyonda:

$$v_t = \mu v_{t-1} + \frac{1}{m} \sum_{i=1}^m \nabla_{\theta} J(\theta_t; x_i, y_i) \quad (3.5)$$

$$\theta_{t+1} = \theta_t - \alpha v_t \quad (3.6)$$

Bu gncelleme kuralı, nceki gradyan bilgisini (momentum) dahil ederek, gradyan iniři srecinde oluřabilecek dalgalanmaları azaltır ve modelin daha stabil bir řekilde yakınsamayı gerekleřtirmesine olanak tanımaktadır [25], [26].

3.4.2. Modellerin eğitiminde kullanılan ADAM algoritması

Adam algoritması, stokastik optimizasyon için tasarlanmış ve gradyanların birinci ve ikinci momentlerinin adaptif tahminlerine dayanan bir yöntemdir. Algoritma, parametre güncelleme sürecinde gradyanların önyargılı birinci moment (m_t) ve ikinci ham moment (v_t) tahminleri kullanır. Güncellemeler şu şekilde tanımlanır, birinci moment (gradyanın ortalaması):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.9)$$

İkinci momentin (gradyanların karelerinin ortalaması):

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.10)$$

Tahmini yapılır. Ardından, bu momentler, başlangıç önyargısını düzeltmek için:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.11)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.12)$$

Olarak normalize edilir ve parametreler daha sonra,

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (3.13)$$

Formülüyle güncellenir. Burada α öğrenme oranı, β_1 ve β_2 momentlerin üstel azalma oranlarını temsil eder ve ϵ hesaplama kararlılığı için küçük bir sabittir. Bu yapı Adam algoritmasının gradyanların ölçeğinden bağımsız çalışmasını ve yüksek gürültü ya da seyrek gradyanlar gibi zorlu durumlarda etkili olmasını sağlar. AfaGraad ve RMSProp yöntemlerinin avantajlarını birleştiren Adam, büyük veri kümelerinde ve yüksek boyutlu parametre uzaylarında etkin bir optimizasyon yöntemi olarak öne çıkar. Algoritmanın önyargı düzeltme mekanizması, özellikle küçük β_2 değerlerinde veya gradyanların seyrek olduğu durumlarda büyük başlangıç önyargılarını engeller ve bu da stabil bir yakınsama süreci sağlamaktadır [27].

3.4.3. Modellerin eğitiminde kullanılan RMSPROP algoritması

Tieleman and Hinton, 2012 yılında oran zamanlamasını koordinat-uyarlamalı öğrenme oranlarından ayırmak için basit bir düzeltme olarak RMSProp algoritmasını önerdi. RMSprop, SGD yönteminin öğrenme oranını adaptif hale getiren bir optimizasyon algoritmasıdır. Bu algoritma, özellikle gradyanların farklı ölçeklerde değişiklik gösterdiği durumlarda, her parametre için ayrı güncelleme katsayıları oluşturarak daha hızlı ve stabil bir yakınsama sağlamaktadır.

Her parametre için gradyanların karelerinin üssel ağırlıklı ortalamasını $E[g^2]_t$ tutmaktadır ve bu değer, her iterasyonda aşağıdaki şekilde güncellenmektedir:

$$E[g^2]_t = \rho E[g^2]_{t-1} + (1 - \rho)g_t^2 \quad (3.7)$$

$E[g^2]_t$, her iterasyonda gradyan karesinin ortalamasını ifade etmektedir. Geçmiş gradyanların kareleri üssel ağırlıklandırma yöntemiyle birikerek güncel değere etki etmektedir. Güncellenen ikinci moment değeri kullanılarak, her parametrenin güncelleme kuralı adaptif öğrenme oranı ile gerçekleştirilir:

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (3.8)$$

Bu formülde $\sqrt{E[g^2]_t + \epsilon}$ ifadesi, güncelleme adımını normalize etmektedir. Gradyanın büyüklüğüne bağlı olarak öğrenme oranı otomatik olarak ayarlanmaktadır. Başlangıçta $E[g^2]_0$ sıfır olarak başlatılır. Her iterasyonda mini-batch üzerinden elde edilen g_t kullanılarak önce $E[g^2]_t$ güncellenmektedir ve parametre güncelleme formülü ile model parametreleri adaptif olarak ayarlanmaktadır [28].

3.5. Karışıklık Matrisi ve Eğitim Grafiklerinin Değerlendirilmesi

Tüm modellerin performansı, doğrulama ve test setleri üzerinde tahmin edilen sınıflar ile gerçek sınıflar arasındaki eşleşmeler analiz edilerek değerlendirilmiştir. Eğitim grafiğinde gözlenen doğrulama doğruluğu, modelin yeni verilerdeki tahmin yeteneğini gösterir. Bu grafikte mavi çizgi ile gösterilen çizgi eğitim doğruluğunu, siyah nokta ile gösterilen doğrulama doğruluğunu göstermektedir. Aynı görsellerde bulunan kayıp grafiğinde turuncu çizgi eğitim sırasındaki modelin hata oranı ve yine kayıp grafiğinde bulunan siyah noktalar doğrulama kaybını göstermektedir. Karışıklık matrisi, her bir sınıfın diğer sınıflarla karışma durumunu göstererek modelin sınıflar arasındaki ayrım gücünü

göstermeye yardımcı olmaktadır. Bu çalışmada kullanılan karışıklık matrislerinde, sınıflar arasındaki doğruluk oranları ve hata oranları gösterilmiştir. Karışıklık matrisinde bulunan diyagonal mavi hücreler doğru sınıflandırılan örnek sayısını, diyagonal dışında bulunan hücrelerdeki sayılar yanlış sınıflandırılan örnek sayısını göstermektedir. Görsellerde bulunan, en alttaki satırlarda yer alan yüzdeler, modelin her bir sınıf için yaptığı tahminlerin ne kadarının doğru olduğunu, en sağdaki sütunlar ise ilgili sınıfa ait örneklerin model tarafından ne kadarının doğru sınıflandırıldığını ifade etmektedir.



4. DENEYSEL SONUÇLAR

CNN ve CNN-SVM modeline ait sonuçlar, farklı optimizasyon algoritmaları (RMSprop, SGDM, Adam), öğrenme oranları (yüksek öğrenme oranı 0,01, orta düzey öğrenme oranı 0,001 ve düşük öğrenme oranı 0,0001) ve epok sayıları 10'dan 100'e kadar değiştirilerek analiz edilmiştir.

4.1. CNN Modelinin Değerlendirilmesi

CNN modelinde üç farklı başlangıç öğrenme oranı, farklı optimizasyon algoritmaları ve epok sayıları değiştirilerek çıkan sonuçlar değerlendirilmiştir.

4.1.1. CNN modelinin eğitiminde SGDM algoritmasının kullanılması

CNN modeli SGDM algoritması kullanılarak elde edilen doğrulama doğruluğu ve test doğruluğu oranlarını detaylı bir şekilde Tablo 4.1.'de belirtilmiştir. Elde edilen sonuçlarda, hangi parametrelerin sabit veya değiştiği gösterilmektedir.

Tablo 4.1. CNN Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc
10	0,01	sgdm	69,77	68,90%
20	0,01	sgdm	69,64	71,98%
30	0,01	sgdm	64,71	63,27%
40	0,01	sgdm	66,44	63,54%
50	0,01	sgdm	13,32	13,27%
60	0,01	sgdm	65,25	67,16%
70	0,01	sgdm	62,85	62,74%
80	0,01	sgdm	62,58	62,87%
90	0,01	sgdm	65,51	66,35%
100	0,01	sgdm	60,85	65,42%
10	0,001	sgdm	87,35	85,52%
20	0,001	sgdm	88,95	89,14%
30	0,001	sgdm	90,28	89,28%
40	0,001	sgdm	90,01	92,09%
50	0,001	sgdm	88,81	90,62%
60	0,001	sgdm	90,68	89,68%
70	0,001	sgdm	91,88	91,82%
80	0,001	sgdm	90,15	88,87%
90	0,001	sgdm	90,81	89,81%
100	0,001	sgdm	92,41	91,69%
10	0,0001	sgdm	83,89	83,24%
20	0,0001	sgdm	82,02	85,26%
30	0,0001	sgdm	84,42	85,12%
40	0,0001	sgdm	84,82	87,27%
50	0,0001	sgdm	90,15	89,14%
60	0,0001	sgdm	89,61	88,61%
70	0,0001	sgdm	90,28	91,02%
80	0,0001	sgdm	91,74	89,28%
90	0,0001	sgdm	89,75	89,54%
100	0,0001	sgdm	89,88	90,35%

Tablo 4.1. incelendiğinde, yüksek öğrenme oranı 0,01 ile eğitilen modelin performansının başlangıçta düşük ve dengesiz olduğu görülmektedir. 10 epok sonunda doğrulama doğruluğu %69,77 iken test doğruluğu %68,90 seviyesindedir. Epok değeri artıkça (örneğin 20 epokta) test doğruluğunda az bir oranda yükselme (%71,98) gözlenirse de epok değerinin daha fazla artırılması performansta ani düşüşlere sebep olmuş; 50 epok değeri doğrulama ve test doğruluğu sırasıyla %13,32 ve %13,27 gibi oldukça düşük seviyelere gerilemiştir. Bu ani düşüş, modelin yüksek öğrenme oranı nedeniyle eğitimin istikrarsız hale geldiğini ve modelin yerel minimumları kaçırdığını veya gradyanların aşırı dalgalanma gösterdiği söylenebilir. Epok sayısının 60, 70, 80 ve sonraki değerlerinde ise doğruluk

oranları tekrar yükselmiş olsa da tutarlı ve kararlı bir performans sağlayamamıştır. Bu durum, yüksek öğrenme oranının model eğitiminde istikrarsızlıklara yol açtığını ve modelin genelleme kabiliyetini zayıflattığını ortaya koymaktadır.

Orta seviyedeki öğrenme oranı 0,001, performans açısından tablodaki en iyi sonuçları vermiştir. Daha düşük öğrenme oranı, modelin eğitim sürecinde daha istikrarlı ve düzenli adımlarla parametrelerini güncellemesini sağlamıştır. Bu da modelin doğrulama ve test setlerinde tutarlı bir şekilde yüksek doğruluk oranlarına ulaşmasını mümkün kılmıştır. Başlangıçta, 10 epokta doğrulama doğruluğu %87,35 ve test doğruluğu %85,52 seviyesindeyken, epok değerinin artışıyla doğruluk oranlarında yükselmeler kaydedilmiştir. Özellikle 40 epokta test doğruluğunun %92,09 gibi oldukça yüksek bir değere ulaştığı gözlemlenmiştir. Eğitim süreci boyunca doğrulama ve test doğruluk oranlarının çoğunlukla %88-%92 arasında dengeli sonuçlar elde edilmesi, kullanılan öğrenme oranının model eğitiminde oldukça ideal olduğunu göstermektedir. 100 epokta doğrulama doğruluğunun %92,41, test doğruluğunun ise %91,69 gibi yüksek ve kararlı bir seviyede kalmaya devam ettiği görülmüştür. Bu sonuçlar, öğrenme oranının dikkatli şekilde ayarlanmasının modelin daha başarılı, kararlı ve genellenebilir sonuçlar üretmesine katkıda bulunduğunu göstermektedir.

Düşük öğrenme oranı olan 0,0001 kullanıldığında, performans gelişiminin daha kademeli gerçekleştiği gözlenmiştir. 10 epok değerinde doğrulama doğruluğu %83,89 ve test doğruluğu %83,24 seviyesindedir. Epok değeri artıkça doğruluk oranlarında düzensiz ancak genel olarak yükselen bir doğrulama doğruluğu görülmüştür. Özellikle epok sayısı 50'ye yaklaştığında performansta belirgin bir iyileşme gözlenmiş, doğrulama ve test doğrulukları sırasıyla %90,15 ve %89,14 gibi yüksek seviyelere ulaşmıştır. Epok sayısının daha da artırılmasıyla (70 epokta %91,02 test doğruluğu), performansta kararlılık ve genellenebilirlik açısından pozitif gelişmeler sağlanmıştır. 100 epok sonunda %89,88 doğrulama ve %90,35 test doğruluğu, performansta önemli ölçüde yeni bir gelişme olmadığı ve belirli bir doygunluk noktasına ulaşıldığı anlaşılmıştır. Bu durum, düşük öğrenme oranının daha uzun eğitim süreleri gerektirdiğini ancak sonuçların tutarlı ve güvenilir olduğunu ortaya koymaktadır.

4.1.2. CNN modelinin eğitiminde Adam algoritmasının kullanılması

CNN modelinin eğitiminde Adam algoritması kullanılarak elde edilen doğrulama doğruluğu ve test doğruluğu oranları Tablo 4.2.'de belirtilmiştir. Elde edilen sonuçlarda, hangi parametrelerin sabit kaldığı veya değiştiği gösterilmektedir.

Tablo 4.2. CNN Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc
10	0,01	adam	74,43	75,34%
20	0,01	adam	69,51	69,71%
30	0,01	adam	72,17	73,86%
40	0,01	adam	79,49	83,38%
50	0,01	adam	76,7	77,21%
60	0,01	adam	71,5	71,18%
70	0,01	adam	79,23	78,82%
80	0,01	adam	76,17	75,20%
90	0,01	adam	69,64	74,13%
100	0,01	adam	74,97	74,67%
10	0,001	adam	85,62	84,18%
20	0,001	adam	84,02	84,45%
30	0,001	adam	83,62	86,60%
40	0,001	adam	82,56	85,39%
50	0,001	adam	85,75	86,73%
60	0,001	adam	88,02	86,06%
70	0,001	adam	88,42	87,13%
80	0,001	adam	86,82	87,13%
90	0,001	adam	84,82	83,11%
100	0,001	adam	87,22	86,60%
10	0,0001	adam	87,22	86,06%
20	0,0001	adam	87,75	86,73%
30	0,0001	adam	87,62	86,60%
40	0,0001	adam	87,08	86,86%
50	0,0001	adam	89,35	89,41%
60	0,0001	adam	90,41	89,54%
70	0,0001	adam	90,95	90,21%
80	0,0001	adam	90,55	88,87%
90	0,0001	adam	91,34	89,81%
100	0,0001	adam	92,68	93,30%

Adam optimizasyon algoritmasıyla eğitilen CNN modelinin, farklı öğrenme oranları ve farklı epok sayılarında gösterdiği performans incelenmiştir. Yapılan analizler, doğrulama ve test doğruluk oranları üzerinden değerlendirilmiştir.

Model ilk olarak, başlangıç öğrenme oranı 0,01 ile eğitilmiştir. Bu başlangıç öğrenme oranı ile eğitildiğinde, doğrulama doğruluğu ve test doğruluğu oranlarında modelde kullanılan diğer öğrenme oranlarına kıyasla farklılıklar görülmüştür. Modelin doğrulama doğruluğu 10 epokta %74,43 ile başlamış, 20 epokta %69,51 seviyesine düşmüş ve ardından

40 epokta %79,49 ile en yüksek doğruluk seviyesine ulaşmıştır. Ancak epok değerinin artmasıyla doğruluk değerlerinde düzenli olmayan iniş çıkışlar gözlenmektedir. Test doğruluğu açısından değerlendirildiğinde, en yüksek performans %83,38 doğruluk oranıyla 40 epokta elde edilmiştir. Daha sonraki epoklarda ise performans tekrar düşüş göstermiş, genel olarak %70-78 arasında değişen sonuçlar ortaya çıkmıştır. Bu durum, yüksek öğrenme oranının Adam optimizasyon algoritmasıyla kullanıldığında modelin kararlılığını olumsuz etkilediğini göstermektedir.

Orta düzeydeki öğrenme oranı 0,001 ile eğitilen modelin sonuçlarında birbirine daha yakın sonuçlar elde edilmiştir. Doğrulama doğruluğu başlangıçta 10 epok için %85,62 iken, epok sayısı artıkça doğruluk oranlarında farklılıklar görülmüş ama genellikle %84 ile %88 arasında tutarlı kalmıştır. Modelin en yüksek doğrulama doğruluğu %88,42 ile 70 epokta elde edilmiştir. Test doğruluğu bakımından ise epok artışıyla birlikte performansta kademeli iyileşmeler gözlenmektedir. 30 epokta %86,60 olan test doğruluğu, 50 epokta %86,73 seviyesine ve 70 epokta %87,13 ile maksimum değerine ulaşmaktadır. 100 epok değeri verildiğinde ise test doğruluğunda önemli bir artış sağlanmamış, %86,60 doğruluk oranıyla sona ermiştir. Bu sonuçlar, Adam algoritmasıyla orta seviyeli öğrenme oranının istikrarlı ve güvenilir bir eğitim süreci sunduğunu göstermektedir.

Düşük öğrenme oranı olan 0,0001 ile yapılan eğitim sonuçları incelendiğinde ise modelin performansının en kararlı ve yüksek olduğu durum ortaya çıkmıştır. Doğrulama doğruluğu 10 epokta %87,22 ile başlamış, epok sayısı artıkça düzenli olarak artan doğrulama doğruluğu oranları elde edilmiştir. Bu öğrenme oranı ile en yüksek doğrulama doğruluğu %92,68 ile 100 epokta elde edilmiştir. Test doğruluğu sonuçları da doğrulama doğruluğu sonuçlarıyla paralel olarak sürekli iyileşme göstermiştir. Başlangıç olarak 10 epokta %86,06 olan test doğruluğu, epok sayısı artıkça kademeli bir artış göstermiş, özellikle 50 epok sonrasında %89 değerlerini geçtiği görülmüştür. Model, 100 epok sonunda ise %93,30 gibi oldukça yüksek ve başarılı bir test doğruluk değerine ulaşmaktadır. Düşük öğrenme oranı, Adam algoritmasının model ağırlıklarını küçük ve kontrollü adımlarla güncelleyerek kararlı bir eğitim sağlamasına imkân vermiş ve modelin genelleme yeteneğini geliştirmiştir.

4.1.3. CNN modelinin eğitiminde RMSprop algoritmasının kullanılması

CNN modelinin eğitiminde RMSprop algoritması kullanılarak elde edilen doğrulama doğruluğu ve test doğruluğu oranlarını detaylı bir şekilde Tablo 4.3.'te belirtilmiştir. Elde edilen sonuçlarda, hangi parametrelerin sabit kaldığı veya değiştiği gösterilmektedir.

Tablo 4.3. CNN Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc
10	0,01	Rmsprop	70,04	67,02%
20	0,01	Rmsprop	71,24	74,40%
30	0,01	Rmsprop	71,11	71,05%
40	0,01	Rmsprop	69,51	74,53%
50	0,01	Rmsprop	68,44	67,02%
60	0,01	Rmsprop	76,43	75,60%
70	0,01	Rmsprop	67,78	69,57%
80	0,01	Rmsprop	79,63	78,02%
90	0,01	Rmsprop	74,57	71,72%
100	0,01	Rmsprop	70,71	70,38%
10	0,001	Rmsprop	83,75	84,58%
20	0,001	Rmsprop	79,76	78,69%
30	0,001	Rmsprop	79,63	81,50%
40	0,001	Rmsprop	79,09	80,83%
50	0,001	Rmsprop	84,95	84,58%
60	0,001	Rmsprop	83,22	82,98%
70	0,001	Rmsprop	87,48	87,27%
80	0,001	Rmsprop	88,42	86,46%
90	0,001	Rmsprop	83,89	85,93%
100	0,001	Rmsprop	88,42	88,20%
10	0,0001	Rmsprop	87,35	89,28%
20	0,0001	Rmsprop	90,01	88,47%
30	0,0001	Rmsprop	87,48	87,00%
40	0,0001	Rmsprop	87,75	87,40%
50	0,0001	Rmsprop	89,48	89,54%
60	0,0001	Rmsprop	86,55	89,41%
70	0,0001	Rmsprop	90,01	86,86%
80	0,0001	Rmsprop	84,02	83,51%
90	0,0001	Rmsprop	89,08	89,81%
100	0,0001	Rmsprop	91,61	89,14%

Başlangıç öğrenme oranı 0,01 değeri için elde edilen ilk sonuçlarda, modelin doğruluk performansının genel olarak düşük ve dalgalı olduğu gözlenmiştir. İlk olarak 10 epokta doğrulama doğruluğu %70,04; test doğruluğu ise %67,02 olarak gerçekleşmiştir. Epok sayısı artırıldığında düzensiz dalgalanmalar oluşmuş, test doğruluğu 20 epok sonunda %74,40 seviyesine ulaşmıştır. 50 epokta, doğrulama ve test doğruluklarının sırasıyla %68,44 ve %67,02 gibi düşük değerler elde edildiği görülmektedir. 80 epokta ise doğrulama ve test doğruluğu oranlarında, 0,01 öğrenme oranı için en yüksek doğrulama doğruluğu %79,63 ve


test doğruluğu %78,02 değerlerine ulaşılmıştır. Daha sonrasında 90 ve 100 epokta bu performans tekrar korunamamıştır.

Orta seviyedeki öğrenme oranı 0,001 ile gerçekleştirilen eğitim sonuçları değerlendirildiğinde, modelin doğruluk oranlarının daha istikrarlı ve genel olarak daha yüksek seviyede seyrettiği görülmektedir. İlk 10 epokta doğrulama doğruluğu %83,75, test doğruluğu ise %84,58 düzeyindedir. Epok sayısının artmasıyla birlikte doğruluk oranlarında dalgalanmalar görülmüş olsa da genel bir yükselme eğilimi söz konusudur. 50 epok sonunda doğrulama doğruluğu oranı %84,95 ve test doğruluğu %84,58 seviyesine ulaşmıştır. 70 ve 80 epoklarda doğrulama doğruluğu sırasıyla %87,48 ve %88,42 ile 0,001 öğrenme oranındaki maksimum değerine ulaşmıştır. Bu epoklarda test doğruluk oranları da oldukça yüksektir (70 epokta %87,27 ve 80 epokta %86,46). Eğitim süreci 100 epok değerindeyken, modelin doğrulama doğruluğu %88,42, test doğruluğu ise %88,20 oranlarında gerçekleşmiştir.

Düşük öğrenme oranı 0,0001 kullanılarak yapılan eğitimde, doğruluk oranlarının başlangıçtan itibaren yüksek seviyelerde seyrettiği ve model performansının genel olarak stabil olduğu görülmektedir. 10 epok sonunda bile doğrulama doğruluğu %87,35, test doğruluğu ise %89,28 gibi yüksek bir başlangıç oranı sergilemiştir. Epok sayısı artıkça performansta istikrarlı bir şekilde artış olmuş, 20 epok sonunda doğrulama doğruluğu %90,01, test doğruluğu ise %88,47 gibi yüksek değerlere ulaşmıştır. 50 epok sonunda elde edilen doğrulama doğruluğu %89,48 ve test doğruluğu %89,54 olarak gerçekleşmiştir. Eğitim sürecinin sonuna yaklaşıldığında, doğruluk değerlerinde belirli dalgalanmalar yaşanmış olmasına rağmen modelin genel performansı yüksek kalmıştır. 100 epok ile eğitim sürecinde, doğrulama doğruluğu %91,61, test doğruluğu ise %89,14 olarak kaydedilmiştir. Düşük öğrenme oranı kullanımı, modelin eğitim sürecinde daha kontrollü ve stabil bir şekilde öğrenme gerçekleştirmesini sağlamış, yüksek genelleme yeteneği kazanmasına imkân tanımıştır.


4.1.4. CNN modelinde elde edilen en yüksek test doğruluğunun analizi

CNN modeli en yüksek test doğruluğu oranını 100 epok, 0.0001 başlangıç öğrenme oranı ve Adam algoritmasıyla elde etmiştir. Test doğruluğu %93,30 ve doğrulama doğruluğu %92,68'dir.



Şekil 4.1 CNN Modelinin En Yüksek Test Doğruluğuna Ait Eğitim Grafiği

Şekil 4.1'deki eğitim sürecine ait doğruluk ve kayıp grafiği incelendiğinde, eğitim doğruluğunun maksimum seviyesine kadar ulaştığı ve doğrulama doğruluğunun %92,68'de sabit kaldığı görülmektedir. Eğitim ve doğrulama doğruluğu arasındaki fark yaklaşık %6-7 oranındadır. Bu durum aşırı öğrenme riskinin oluşmadığını ve modelin dengeli bir biçimde eğitildiğini göstermektedir. Eğitim kaybı hızlı bir şekilde azalmış ve sıfır değerine yaklaşarak sabitlenmiştir. Doğrulama kaybı yüksek bir değerden başlayarak hızla düşmüş ve eğitim boyunca 0,3 seviyelerinde sabit kalmıştır. Eğitim kaybı ile doğrulama kaybı arasındaki fark, düşük seviyelerde kalarak modelin genelleme yeteneğini kaybetmediğini göstermektedir.



Şekil 4.2 CNN Modelinin En Yüksek Test Doğruluğuna Ait Karışıklık Matrisi

Şekil 4.2’deki karışıklık matrisi incelendiğinde modelin test doğruluğu birçok sınıf için yüksek seviyede olduğu söylenebilmektedir. Özellikle B-2, C-5 E-3 ve KC-10 sınıflarında %95’in üzerinde doğruluk oranları elde edilmiştir. B-52, C-130 ve C-135 sınıflarında sınıflar arası karışıklıklar diğer sınıflara göre daha fazladır. Bu durum sınıfların görsel özelliklerinin benzerliklerinden kaynaklanmaktadır.

4.2. Veri Artırma İşlemi Uygulanan CNN Modelinin Değerlendirilmesi

CNN modeline veri artırma işlemi uygulandıktan sonra elde edilen sonuçlar karşılaştırılmıştır. Farklı başlangıç öğrenme oranı, farklı optimizasyon algoritmaları ve epok sayıları değiştirilerek alınan sonuçlar değerlendirilmiştir.

4.2.1. Veri artırma işlemi uygulanan CNN modelinin eğitiminde SGDM algoritmasının kullanılması

Veri artırma tekniği uygulanarak CNN modeli değerlendirilmiştir. Model eğitiminde SGDM optimizasyon algoritması, farklı öğrenme oranları ve değişen epok sayıları

kullanılarak performans analizi gerçekleştirilmiştir. Elde edilen doğrulama doğruluğu ve test doğruluğu değerleri ayrıntılı olarak analiz edilmiş ve hangi parametrelerin sabit, hangilerinin değişken olduğu Tablo 4.4.'te belirtilmiştir.

Tablo 4.4. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc (%)	Test Acc.
10	0,001	sgdm	91,88	91,02%
20	0,001	sgdm	93,74	93,97%
30	0,001	sgdm	93,74	94,91%
40	0,001	sgdm	95,21	94,10%
50	0,001	sgdm	95,47	96,11%
60	0,001	sgdm	96,14	94,24%
70	0,001	sgdm	95,74	95,44%
80	0,001	sgdm	96,14	96,52%
90	0,001	sgdm	95,87	95,71%
100	0,001	sgdm	94,27	94,64%
10	0,0001	sgdm	76,56	80,03%
20	0,0001	sgdm	86,02	85,66%
30	0,0001	sgdm	86,02	87,94%
40	0,0001	sgdm	91,08	90,48%
50	0,0001	sgdm	92,54	92,36%
60	0,0001	sgdm	91,34	93,03%
70	0,0001	sgdm	92,01	90,89%
80	0,0001	sgdm	92,81	92,23%
90	0,0001	sgdm	92,28	93,03%
100	0,0001	sgdm	92,28	92,09%

Tablo 4.4.'te sunulan verilere göre, orta seviyedeki öğrenme oranıyla (0,001) eğitilen modelin performansı oldukça yüksek ve istikrarlı sonuçlar alınmasını sağlamıştır. Eğitim sürecinin ilk aşamalarında dahi (10 epok) model, %91,88 doğrulama ve %91,02 test doğruluğuyla yüksek bir başlangıç sergilemiştir. Epok sayısının artmasıyla birlikte doğruluk oranlarında dikkate değer bir yükseliş görülmüş, 20 epok değerinde doğrulama doğruluğu %93,74 ve test doğruluğu %93,97 gibi oldukça yüksek seviyelere ulaşmıştır. Eğitim sürecinde doğrulama doğruluğu, epok sayısı arttıkça artmaya devam etmiş ve özellikle 50 ile 80 epok arasında %95'in üzerinde tutarlı ve yüksek değerlerde kalmıştır. Bu epok değerlerinde, test doğruluğu da yüksek seviyelere ulaşmış, özellikle 50 epok değerinde %96,11 ve 80 epok değerinde %96,52 ile maksimum oranlar elde edilmiştir. Modelin bu aşamalarda elde ettiği yüksek doğruluk oranları, orta öğrenme oranının veri artırma

uygulanan CNN eğitiminde güçlü ve güvenilir sonuçlar verdiğini göstermektedir. Eğitim sonunda (100 epok) doğrulama doğruluğunun %94,27, test doğruluğunun ise %94,64 olarak gerçekleştiği görülmektedir. Modelin genel doğruluğu son epoklarda dalgalanma yaşasa da genel olarak yüksek performansını sürdürmüş ve genelleme yeteneği konusunda başarılı bir performans göstermiştir.

Daha düşük öğrenme oranı 0,0001 kullanılarak gerçekleştirilen eğitimde, modelin doğruluk oranları ilk epoklarda daha düşük seviyelerde başlamıştır. Başlangıçta doğrulama doğruluğu %76,56, test doğruluğu ise %80,03 olarak kaydedilmiştir. Epok sayısının artmasıyla birlikte, modelin doğruluk oranları istikrarlı bir yükseliş eğilimi göstermiştir. Epok sayısı artıkça doğrulama ve test doğruluğunda düzenli iyileşmeler gözlenmiştir. Özellikle 40 epokta doğrulama doğruluğu %91,08 ve test doğruluğu %90,48 gibi yüksek değerlere çıkmaktadır. 50 epokta doğrulama doğruluğu %92,54, test doğruluğu ise %92,36 seviyesine ulaşarak iyi bir performans ortaya koymuştur. Epok sayısının daha da artmasıyla doğruluk oranları %91-92 seviyesinde küçük dalgalanmalarla devam etmiş, model yüksek genelleme kabiliyetini korumuştur. Eğitim sonunda (100 epok) doğrulama doğruluğu %92,28, test doğruluğu ise %92,09 olarak gerçekleşmiştir. Bu durum, düşük öğrenme oranının daha uzun eğitim süreçlerinde tutarlı ve iyi performans sağladığını ancak daha hızlı bir öğrenmeye kıyasla daha uzun süreli eğitimlere ihtiyaç duyduğunu göstermektedir.

4.2.2. Veri artırma işlemi uygulanan CNN modelinin eğitiminde Adam algoritmasının kullanılması

Veri artırma tekniği uygulanarak CNN modeli değerlendirilmiştir. Model eğitiminde Adam optimizasyon algoritması, farklı öğrenme oranları ve değişken epok değerleri kullanılarak performans analizi gerçekleştirilmiştir. Elde edilen doğrulama doğruluğu ve test doğruluğu değerleri ayrıntılı olarak analiz edilmiş ve hangi parametrelerin sabit kaldığı, hangilerinin değişken olduğu Tablo 4.5.'te belirtilmiştir.

Tablo 4.5. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc(%)	Test Acc.
10	0,001	adam	86,55	85,93%
20	0,001	adam	91,34	91,69%
30	0,001	adam	89,61	91,69%
40	0,001	adam	84,81	96,25%
50	0,001	adam	94,41	94,50%
60	0,001	adam	93,48	94,10%
70	0,001	adam	94,01	93,70%
80	0,001	adam	94,81	96,25%
90	0,001	adam	94,41	95,71%
100	0,001	adam	94,67	95,58%
10	0,0001	adam	87,62	87,40%
20	0,0001	adam	93,48	93,70%
30	0,0001	adam	94,94	94,50%
40	0,0001	adam	94,01	93,83%
50	0,0001	adam	94,01	93,57%
60	0,0001	adam	95,34	95,31%
70	0,0001	adam	94,01	94,50%
80	0,0001	adam	95,87	96,11%
90	0,0001	adam	94,94	94,64%
100	0,0001	adam	94,41	93,43%

Model orta seviyedeki öğrenme oranıyla (0,001) yapılan eğitimlerde, başlangıçtan itibaren yüksek bir performans sergilemiştir. İlk aşamada, 10 epok sonunda doğrulama doğruluğu %86,55, test doğruluğu ise %85,93 olarak gerçekleşmiştir. Epok sayısı artırılarak eğitim devam ettikçe, modelin doğruluğunda önemli artışlar gözlenmiştir. 20 epok sonunda doğrulama doğruluğu %91,34 ve test doğruluğu %91,69 gibi yüksek değerlere ulaşmıştır. Epok sayısı 40'a ulaştığında doğrulama doğruluğunda (%84,81) küçük bir düşüş yaşanmasına rağmen test doğruluğunun %96,25 gibi çok yüksek bir değerle zirve yapması dikkate değerdir. Bu durum, modelin bu noktada test verilerini daha iyi genellelebildiğini göstermektedir. Epok sayısının daha da artmasıyla, doğrulama doğruluğu tekrar yükselerek 50 epokta %94,41'e ulaşmıştır. Bu noktadan sonra doğrulama ve test doğrulukları genel olarak istikrarlı bir seyir izleyerek yüksek değerlerde (%94-96 arası) kalmıştır. Eğitimin sonunda (100 epok), doğrulama doğruluğu %94,67, test doğruluğu ise %95,58 gibi çok yüksek ve başarılı bir seviyede tamamlanmıştır.

Daha düşük bir öğrenme oranı (0,0001) kullanılarak gerçekleştirilen eğitimde, başlangıçtaki doğrulama doğruluğu %87,62 ve test doğruluğu %87,40 seviyelerinde başlamıştır. Epok sayısı artıkça modelin doğruluğu istikrarlı biçimde yükselmiş, özellikle 20 epok sonunda doğrulama doğruluğu %93,48, test doğruluğu ise %93,70 seviyesine ulaşmıştır. Eğitimin ilerleyen aşamalarında doğrulama ve test doğruluklarında küçük oranlarda dalgalanmalar görülmüş olsa da genel olarak yüksek performans korunmuştur. Özellikle 60 epokta %95,34 doğrulama ve %95,31 test doğruluğu elde edilmiş, bu noktada modelin performansı maksimum seviyeye ulaşmıştır. 80 epok sonunda ise doğrulama doğruluğu %95,87, test doğruluğu %96,11 ile en yüksek değerleri görmüştür. Epok sayısının maksimuma ulaştığı noktada (100 epok), doğrulama doğruluğu %94,41, test doğruluğu ise %93,43 olarak ölçülmüştür. Eğitim sonunda hafif bir düşüş yaşanmış ancak genel olarak model performansının düşük öğrenme oranıyla birlikte yüksek ve tutarlı olduğu net şekilde görülmektedir.

4.2.3. Veri artırma işlemi uygulanan CNN modelinin eğitiminde RMSprop algoritmasının kullanılması

Veri artırma tekniği ve RMSprop algoritması uygulanan CNN modeli değerlendirilmiştir. Model eğitiminde farklı öğrenme oranları ve değişen epok sayıları kullanılarak performans analizi gerçekleştirilmiştir. Elde edilen doğrulama doğruluğu ve test doğruluğu değerleri ayrıntılı olarak analiz edilmiş ve hangi parametrelerin sabit kaldığı, hangilerinin değişken olduğu Tablo 4.6.'da belirtilmiştir.

Tablo 4.6. Veri Artırma İşlemi Uygulanan CNN Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc(%)	Test Acc.
10	0,001	Rmsprop	81,36	83,78%
20	0,001	Rmsprop	90,81	89,28%
30	0,001	Rmsprop	92,68	93,03%
40	0,001	Rmsprop	94,01	93,97%
50	0,001	Rmsprop	92,28	92,49%
60	0,001	Rmsprop	95,34	96,11%
70	0,001	Rmsprop	97,47	96,25%
80	0,001	Rmsprop	94,54	94,77%
90	0,001	Rmsprop	95,21	92,36%
100	0,001	Rmsprop	94,14	93,70%
10	0,0001	Rmsprop	72,30	71,98%
20	0,0001	Rmsprop	88,68	87,00%
30	0,0001	Rmsprop	84,02	83,78%
40	0,0001	Rmsprop	88,55	88,20%
50	0,0001	Rmsprop	94,81	94,37%
60	0,0001	Rmsprop	90,68	89,01%
70	0,0001	Rmsprop	93,08	93,83%
80	0,0001	Rmsprop	93,21	93,03%
90	0,0001	Rmsprop	92,41	95,17%
100	0,0001	Rmsprop	95,87	92,90%


Orta düzey öğrenme oranıyla (0,001) RMSProp kullanılarak eğitilen model, ilk epoklarda hızlı bir ilerleme kaydetmiştir. 10 epok sonunda %81,36 doğrulama doğruluğu ve %83,78 test doğruluğu elde edilmiştir. Epok sayısının artmasıyla birlikte, doğrulama ve test doğruluklarında hızlı ve tutarlı bir artış gözlemlenmiştir. Özellikle 30 epokta doğrulama doğruluğu %92,68, test doğruluğu ise %93,03 gibi yüksek değerlere ulaşmıştır. 40 epok değerinde, doğrulama doğruluğu %94,01 ve test doğruluğu %93,97 seviyesine yükselmiştir. En yüksek doğrulama doğruluğu 70 epokta %97,47 ile elde edilirken, test doğruluğu da %96,25 gerçekleşerek modelin genelleme yeteneğinin üst düzey olduğunu göstermiştir. Epok sayısının artmasıyla (80-100 epok arası), doğruluk oranlarında küçük dalgalanmalar görülmekle birlikte genel olarak yüksek değerlerde (%94-96 civarı) kalmıştır. 100 epokta, doğrulama doğruluğu %94,14, test doğruluğu ise %93,70 olarak gerçekleşmiştir.

Düşük öğrenme oranı 0,0001 ile eğitilen model ilk aşamada daha düşük doğruluk oranlarıyla başlamıştır. 10 epok sonunda %72,30 doğrulama ve %71,98 test doğruluğu ile nispeten daha zayıf bir performans sergilemiştir. Ancak epok sayısı artıkça model doğruluk oranlarında tutarlı bir artış göstermiştir. 20 epok sonunda doğrulama doğruluğu %88,68

seviyesine, test doğruluğu ise %87 seviyesine ulaşmıştır. Model performansında epok sayısına bağlı dalgalanmalar görülmüş; örneğin, 30 epokta doğrulama doğruluğu %84,02'ye düşerken, 40 epokta tekrar %88,55 doğrulama ve %88,20 test doğruluğuyla yükselişe geçmiştir. Bu doğruluk değerleri 50 epokta %94,81 doğrulama ve %94,37 test doğruluğuyla en yüksek değerlerine ulaşarak modelin güçlü bir öğrenme sürecinden geçtiğini göstermiştir. Epok sayısının ilerleyen aşamalarında (60-90 epok aralığında) doğrulama ve test doğrulukları %90-%95 aralığındadır ve genel olarak başarılı bir seviyede kalmıştır. Eğitim sonunda (100 epok), doğrulama doğruluğu %95,87 gibi yüksek bir seviyede, test doğruluğu ise %92,90 olarak ölçülmüştür.

4.2.4. Veri artırma işlemi uygulanmış CNN modelinde elde edilen en yüksek test doğruluğunun analizi


CNN modeline veri artırma işlemi uygulandıktan sonra elde edilen en yüksek test doğruluğu oranını 80 epok, 0,001 başlangıç öğrenme oranı ve SGDM algoritmasıyla elde etmiştir. Test doğruluğu %96,52 ve doğrulama doğruluğu %95,14'tür.



Şekil 4.3 Veri Artırma İşlemi Uygulanmış CNN Modelinin En Yüksek Test Doğruluğuna Ait Eğitim Grafiği

Şekil 4.3'teki eğitim sürecine ait doğruluk ve kayıp grafiği incelendiğinde, eğitim doğruluğunun 10. Epok sonrasında %90'ın üzerinde doğruluk seviyelerine ulaştığı görülmektedir. Eğitim tamamlandığında doğruluk değeri maksimum seviyeye yaklaşırken doğrulama doğruluğu %96,14'te sabitlenmiştir. Eğitim ve doğrulama doğruluğu arasındaki fark yaklaşık %3 seviyelerindedir ve modelin öğrenme sürecinde aşırı öğrenme problemi yaşamadığı, genelleme yeteneğine sahip olduğu söylenebilir. Eğitim kaybı hızlı bir biçimde

sıfıra yaklaşırken, doğrulama kaybı yaklaşık 0,3 seviyelerinde dengelenmiştir. Eğitim ve doğrulama kayıpları arasındaki farkın düşük düzeyde kalması, modelin aşırı uyum yaşamadığını göstermektedir.



Şekil 4.4 Veri Artırma İşlemi Uygulanmış CNN Modelinin En Yüksek Test Doğruluğuna Ait Karışıklık Matrisi

Şekil 4.4 incelendiğinde model B-2, E-3 ve KC-10 sınıflarında neredeyse hatasız tahminler yapmıştır. Diğer sınıflarda da modelin her bir gerçek sınıfa ait verileri doğru tahmin etme oranı genellikle %95'in üzerindedir. C-135 sınıfındaki bazı görsellerin C-5, C-130 ve B-52 sınıflarıyla karıştığı, C-5 sınıfına ait bazı görseller de B-52 ve C-135 ile karıştığı görülmektedir. Bu karışıklıkların sebebi görsel benzerliklerden kaynaklanmaktadır.

4.3. CNN-SVM Modelinin Değerlendirilmesi

CNN-SVM modelinde elde edilen sonuçlar karşılaştırılmıştır. Farklı başlangıç öğrenme oranı, farklı optimizasyon algoritmaları ve epok sayıları değiştirilerek alınan sonuçlar değerlendirilmiştir.

4.3.1. CNN-SVM modelinin eğitiminde SGDM algoritmasının kullanılması

SGDM optimizasyon algoritması, öğrenme oranları ve epok sayıları değiştirilip modelin son konvolüsyon katmanından (relu_3) elde edilen derin öğrenme temelli özellikler çıkarılarak, klasik makine öğrenmesi algoritması olan SVM modeline girdi olarak verilmiştir ve modelin performansı analiz edilmiştir. Tablo 4.7., doğrulama doğruluğu ve test doğruluğu oranlarını göstermektedir. Hangi parametrelerin sabit kaldığı veya değiştiği gösterilmektedir.

Tablo 4.7. CNN-SVM Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc.
10	0,01	sgdm	64,58	70,78%
20	0,01	sgdm	13,45	14,34%
30	0,01	sgdm	66,31	67,83%
40	0,01	sgdm	73,5	74,13%
50	0,01	sgdm	70,97	74,40%
60	0,01	sgdm	66,58	74,53%
70	0,01	sgdm	76,96	78,15%
80	0,01	sgdm	65,78	74,80%
90	0,01	sgdm	56,46	58,98%
100	0,01	sgdm	61,25	68,10%
10	0,001	sgdm	88,28	87,00%
20	0,001	sgdm	87,48	88,47%
30	0,001	sgdm	89,88	90,88%
40	0,001	sgdm	91,61	91,15%
50	0,001	sgdm	90,28	90,62%
60	0,001	sgdm	89,75	90,75%
70	0,001	sgdm	87,75	89,01%
80	0,001	sgdm	90,01	92,23%
90	0,001	sgdm	89,48	91,29%
100	0,001	sgdm	90,95	91,96%
10	0,0001	sgdm	82,96	90,48%
20	0,0001	sgdm	85,62	88,74%
30	0,0001	sgdm	87,75	90,48%
40	0,0001	sgdm	88,81	90,08%
50	0,0001	sgdm	87,75	90,75%
60	0,0001	sgdm	88,28	88,74%
70	0,0001	sgdm	86,95	88,87%
80	0,0001	sgdm	88,28	90,08%
90	0,0001	sgdm	88,28	89,68%
100	0,0001	sgdm	88,42	89,41%

CNN modelinden elde edilen derin öğrenme temelli özelliklerin SVM algoritması ile sınıflandırılarak oluşturulan yöntemin performansı, SGDM optimizasyon algoritması kullanılarak eğitilen CNN modeli üzerinden farklı öğrenme oranları ve değişken epok sayıları ile detaylı şekilde incelenmiştir.

SGDM algoritması yüksek öğrenme oranı 0,01 kullanılarak eğitildiğinde, model performansında sürekli değişkenlik göstermiştir. Eğitim sürecinin erken aşamasında (10 epok), %64,58 doğrulama doğruluğu ve %70,78 test doğruluğu elde edilmiştir. Ancak 20 epok sonunda doğrulama ve test doğruluğunda yüksek oranda bir düşüş görülerek doğrulama doğruluğu %13,45'e, test doğruluğu %14,34'e düşmüştür. Epok sayısının artırılmasıyla (30-

70 epok) doğrulama doğruluğu tekrar yükselmiş ancak genel olarak %65-76 arasında sınırlı ve düşük düzeylerde kalmıştır. En yüksek doğrulama doğruluğu %76,96 ve test doğruluğu %78,15 oranlarına 70 epokta ulaşılmıştır. Epok sayısının daha fazla artırılması (80-100 epok aralığı), modelin doğruluğunu artırmak yerine performansta düşüşe neden olmuş, 100 epok sonunda %61,25 doğrulama doğruluğu ve %68,10 test doğruluğu elde edilmiştir.

Orta düzey öğrenme oranı 0,001 kullanıldığında, eğitim sürecinin daha başarılı olduğu görülmektedir. İlk 10 epok sonrasında %88,28 doğrulama doğruluğu ve %87 test doğruluğu elde edilmiştir. Epok sayısının artmasıyla doğrulama doğruluğunda ve test doğruluğunda istikrarlı artışlar görülmüş; özellikle 40 epok sonunda doğrulama doğruluğu %91,61, test doğruluğu ise %91,15 seviyesine ulaşmıştır. Epok sayısının artırılmasıyla (50-100 epok arası), doğrulama ve test doğruluk oranları %87-91 aralığında sabit ve yüksek düzeylerde kalmıştır. Bu süreçteki küçük dalgalanmalara rağmen, yüksek performans genel olarak korunmuştur. 100 epok sonunda doğrulama doğruluğu %90,95, test doğruluğu ise %91,96 gibi oldukça yüksek seviyelerde gerçekleşmiştir.

Düşük öğrenme oranı 0,0001 ile eğitim yapıldığında, başlangıç doğrulama doğruluğu %82,96 ve test doğruluğu %90,48 olarak ölçülmüş ve genel olarak yüksek bir başlangıç performansı sağlanmıştır. Epok sayısının artırılmasıyla doğrulama doğruluklarında düzenli artışlar kaydedilmiş ve 40 epok sonrasında doğrulama doğruluğu %88,81, test doğruluğu ise %90,08 seviyesine ulaşarak yüksek bir performans sergilemiştir. Epok sayısının artırmaya devam edilmesi (50-100 epok) doğruluk değerlerinde küçük dalgalanmalar yaratmış ancak genel olarak modelin doğruluk değerlerini yüksek ve istikrarlı tutmuştur. 100 epok sonunda doğrulama doğruluğu %88,42 seviyesine, test doğruluğu ise %89,41 oranına ulaşmıştır. Bu sonuçlar, düşük öğrenme oranının model performansı açısından başarılı olduğunu göstermektedir.

4.3.2. CNN-SVM modelinin eğitiminde Adam algoritmasının kullanılması

Adam optimizasyon algoritması ile eğitilen CNN modelinden elde edilen derin öğrenme tabanlı özelliklerin, SVM algoritması ile sınıflandırıldığı modelin performansı farklı öğrenme oranları ve epok sayıları değiştirilerek detaylı olarak incelenmiştir. Tablo 4.8.'de doğrulama doğruluğu ve test doğruluğu oranları verilmiştir. Ayrıca hangi parametrelerin sabit kaldığı veya değiştiği gösterilmektedir.

Tablo 4.8. CNN-SVM Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc.
10	0,01	adam	72,3	72,65%
20	0,01	adam	73,64	76,54%
30	0,01	adam	73,9	78,02%
40	0,01	adam	71,5	73,59%
50	0,01	adam	71,5	73,19%
60	0,01	adam	69,64	72,12%
70	0,01	adam	71,5	72,92%
80	0,01	adam	79,76	84,18%
90	0,01	adam	81,36	85,25%
100	0,01	adam	76,7	75,87%
10	0,001	adam	83,36	82,98%
20	0,001	adam	85,49	84,99%
30	0,001	adam	86,68	88,07%
40	0,001	adam	86,82	88,07%
50	0,001	adam	84,29	84,85%
60	0,001	adam	90,41	90,08%
70	0,001	adam	82,16	85,92%
80	0,001	adam	87,35	88,20%
90	0,001	adam	89,21	85,52%
100	0,001	adam	85,75	87,40%
10	0,0001	adam	87,35	89,14%
20	0,0001	adam	88,55	91,29%
30	0,0001	adam	86,02	89,01%
40	0,0001	adam	92,41	88,74%
50	0,0001	adam	87,62	90,48%
60	0,0001	adam	87,75	89,68%
70	0,0001	adam	90,68	91,02%
80	0,0001	adam	89,75	90,62%
90	0,0001	adam	90,95	90,88%
100	0,0001	adam	90,55	89,54%

Yüksek öğrenme oranı 0,01 ile yapılan eğitim sürecinde, model doğrulama doğruluğu ve test doğruluk oranlarında belirgin dalgalanmalar görülmüştür. Başlangıçta, 10 epok sonunda doğrulama doğruluğu %72,3 iken, test doğruluğu %72,65 olarak elde edilmiştir. Epok sayısı olarak 20 ve 30 değerleri kullanıldığında doğruluklarda artışlar yaşanmıştır. Doğrulama doğruluğu 20 epokta %73,64 ve 30 epokta %73,9, test doğruluğu ise 20 epokta %76,54 ve 30 epokta %78,02'ye yükselmiştir. Bu noktada performans sınırlı bir yükseliş göstermiştir. Epok sayısının 50-70 değerleri için model performansı genel olarak %70-72 aralığında sınırlı kalmıştır. Epok sayısının 80 ve 90'a ulaşması ile doğrulama

doğruluğu sırasıyla %79,76 ve %81,36 seviyelerine yükselmiş, test doğruluğu ise 80 epokta %84,18 ve 90 epokta %85,25 oranlarına ulaşmıştır. Ancak 100 epok sonunda doğrulama doğruluğu tekrar düşerek %76,7'ye ve test doğruluğu %75,87 seviyesine gerilemiştir.

Orta düzey öğrenme oranı 0,001 ile eğitilen model, ilk epoklarda yüksek bir performans göstermiş, 10 epok sonunda doğrulama doğruluğu %83,36 ve test doğruluğu %82,98 gibi yüksek seviyelerde gerçekleşmiştir. Epok sayısının artırılmasıyla (20-40 epok) doğrulama doğruluğu oranı 20 epokta %85,49, 30 epokta %86,68 ve 40 epokta %86,82 sonuçları elde edilmiştir. Test doğruluğu oranları ise 20 epokta %84,99, 30 epokta %88,07 ve 40 epokta %88,07 oranlarına ulaşmıştır. Epok sayısının 50 ve 100 epok arasındaki değerlerinde, doğrulama ve test doğruluk oranlarında düzenli olmayan sonuçlar görülmesine rağmen, genel performans yüksek seviyede korunmuştur. Özellikle 60 epokta %90,41 doğrulama doğruluğu ve %90,08 test doğruluğu elde edilerek eğitim sürecinin zirve performanslarından biri yakalanmıştır. Yüksek epok değerlerinde doğruluk oranları ufak dalgalanmalara uğrasa da performans değerleri %85 ile %90 aralığında yüksek düzeylerde seyretmiştir.

Düşük öğrenme oranı 0,0001 ile eğitilen model başlangıçtan itibaren yüksek doğruluk oranları yakalamıştır. 10 epok sonunda doğrulama doğruluğu %87,35, test doğruluğu ise %89,14 seviyesine ulaşmıştır. Epok sayısı artıkça doğruluk oranlarında sürekli artış gözlemlenmiş ve özellikle 20 epokta %88,55 gibi doğrulama doğruluğu oldukça yüksek bir performans seviyesi yakalanmıştır. Bu yüksek doğruluk oranı, test doğruluğuna %91,29 da pozitif etki yapmıştır. 40 ile 100 epok arası süreçte doğrulama ve test doğruluğunda küçük iniş çıkışlar meydana gelse de genel performans değerleri yüksek düzeyde kalmıştır. Epok sayısının artmasıyla, doğrulama doğruluk oranları genellikle %87-92 aralığında, test doğruluk oranları ise %88-91 aralığında kalmıştır. 100 epok değerinde %90,55 doğrulama doğruluğu ve %89,54 test doğruluğu elde edilmiştir. Bu sonuçlar, düşük öğrenme oranının model eğitiminde istikrarlı ve başarılı bir seçim olduğunu ortaya koymaktadır.

4.3.3. CNN-SVM modelinin eğitiminde RMSprop algoritmasının kullanılması

RMSprop optimizasyon algoritması ile eğitilen CNN modelinden elde edilen derin öğrenme tabanlı özelliklerin SVM algoritması ile sınıflandırılmıştır. Modelin performansı farklı öğrenme oranları ve epok sayıları değiştirilerek detaylı olarak incelenmiştir. Elde edilen sonuçlar doğrulama doğruluğu ve test doğruluk oranları açısından değerlendirilmiş ve Tablo 4.9.'da elde edilen bulgular belirtilmiştir.

Tablo 4.9. CNN-SVM Modelinin Eğitiminde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc. (%)	Test Acc,
10	0,01	rmsprop	51,93	69,97%
20	0,01	rmsprop	48,34	79,62%
30	0,01	rmsprop	70,84	73,06%
40	0,01	rmsprop	80,03	83,51%
50	0,01	rmsprop	68,04	74,66%
60	0,01	rmsprop	72,97	72,92%
70	0,01	rmsprop	73,24	75,87%
80	0,01	rmsprop	81,76	78,69%
90	0,01	rmsprop	67,91	74,93%
100	0,01	rmsprop	74,83	78,28%
10	0,001	rmsprop	76,3	82,84%
20	0,001	rmsprop	80,03	84,72%
30	0,001	rmsprop	86,55	87,27%
40	0,001	rmsprop	83,99	85,25%
50	0,001	rmsprop	86,95	90,21%
60	0,001	rmsprop	84,02	82,04%
70	0,001	rmsprop	83,62	87,40%
80	0,001	rmsprop	84,42	88,74%
90	0,001	rmsprop	48,87	84,58%
100	0,001	rmsprop	89,21	88,61%
10	0,0001	rmsprop	82,02	86,86%
20	0,0001	rmsprop	88,28	88,87%
30	0,0001	rmsprop	88,42	87,80%
40	0,0001	rmsprop	87,88	90,48%
50	0,0001	rmsprop	89,75	88,61%
60	0,0001	rmsprop	90,55	91,02%
70	0,0001	rmsprop	91,61	89,28%
80	0,0001	rmsprop	89,61	87,67%
90	0,0001	rmsprop	91,08	90,88%
100	0,0001	rmsprop	90,55	88,07%

0,01 öğrenme oranıyla yapılan eğitimlerde, modelin performansı düzensiz bir seyir izlemiş ve genel olarak düşük değerler kaydedilmiştir. 10 epok sonunda doğrulama doğruluğu %51,93, test doğruluğu ise %69,97 olarak gerçekleşmiştir. Epok sayısı 20'ye yükseltildiğinde doğrulama doğruluğu beklenmedik şekilde %48,34'e düşmüş ancak test doğruluğu %79,62'ye yükselmiştir. Epok sayıları artıkça (30, 40, 50, 60, 70, 80, 90 ve 100 epoklar için), doğrulama doğruluğu oranları %67 ile %81 arasında dalgalanırken test doğruluğu oranları %72 ile %84 arasında nispeten daha yüksek değerlerde seyretmiştir. Bu


durum, yüksek öğrenme oranının, ağın eğitimini zorlaştırdığını ve istikrarsız bir öğrenme davranışı sergilediğini ortaya koymaktadır.

Öğrenme oranının 0,001 değerine düşürülmesiyle, daha istikrarlı ve yüksek performanslı sonuçlar elde edilmiştir. Bu öğrenme oranında 10 epok sonunda doğrulama doğruluğu %76,3 iken, test doğruluğu %82,84 olarak gerçekleşmiştir. Epok sayısı artıkça doğrulama doğruluğu oranları yükselmiş ve 30 epokta %86,55'e, test doğruluğu ise %87,27'ye ulaşmıştır. Ancak 90 epokta doğrulama doğruluğunda yaşanan ani düşüş (%48,87), eğitim sırasında aşırı uyum olduğunu göstermektedir. Epok sayısı 100'e ulaştığında doğrulama doğruluğunda en yüksek değerlerden biri olan %89,21'e ulaşılırken, test doğruluğunda da %88,61 gibi yüksek bir değer elde edilmiştir.

Öğrenme oranının 0,0001 gibi daha düşük bir değer verilmesiyle model performansı daha tutarlı ve yüksek değerlere ulaşmıştır. Başlangıçta 10 epok sonrası doğrulama doğruluğu %82,02 iken, test doğruluğu %86,86'dır. Epok sayıları artıkça doğruluk değerleri stabil bir şekilde artış göstermiş, 50 epok sonunda %89,75 doğrulama doğruluğu ve %88,61 test doğruluğu değerlerine ulaşılmıştır. Epok sayısı 60 olduğunda ise %90,55 doğrulama doğruluğu ve %91,02 test doğruluğu elde edilmiştir. Epok sayısı 100'e yükseldiğinde doğrulama doğruluğu %90,55, test doğruluğu ise %88,07 olarak gerçekleşmiştir. Bu değerler, 0,0001 öğrenme oranının eğitim sırasında istikrarlı bir iyileşme sağladığını ve modelin daha tutarlı sonuçlar verdiğini göstermektedir.


4.3.4. CNN-SVM modelinde elde edilen en yüksek test doğruluğunun analizi

CNN-SVM modelinde elde edilen en yüksek test doğruluğu oranını 80 epok, 0.001 başlangıç öğrenme oranı ve SGDM algoritmasıyla elde etmiştir. Test doğruluğu %92,23 ve doğrulama doğruluğu %90,01'dir.



Şekil 4.5 CNN-SVM Modelinin En Yüksek Test Doğruluğuna Ait Eğitim Grafiği

Şekil 4.5'e bakıldığında eğitim eğrisi 10. epoktan sonra maksimum sınıra çıkarak sabitlenmiştir. Bu durum modelin eğitim verisi üzerinde yüksek bir başarı sergilediğini göstermektedir. Doğrulama doğruluğu %90,01 seviyesinde sabitlenmiştir. Eğitim ve doğrulama doğruluğu arasındaki yaklaşık %10'luk fark, modelin eğitim sürecinde iyi bir uyum sağladığını ancak yeni veriler üzerinde genelleme yeteneğinin diğer modellere göre düşük kaldığını göstermektedir. Kayıp grafiğinde eğitim kaybının, eğitim sürecinin başlarında hızlıca azaldığı ve sıfıra yakın bir değerde sabit kaldığı gözükmemektedir. Doğrulama kaybı belirli bir seviyede sabitlenmiş ve eğitim kaybının üzerinde sonuçlanmıştır. Eğitim ve doğrulama kayıpları arasındaki farkın az olması modelin aşırı uyum yaşamadığını göstermektedir.



Şekil 4.6 CNN-SVM Modelinin En Yüksek Test Doğruluğuna Ait Karışıklık Matrisi

Şekil 4.6'daki karışıklık matrisi incelendiğinde B-1 sınıfına ait 88 örnek doğru sınıflandırılmış, 3 örnek B-52 ve 3 örnek KC-10 sınıfları ile karışmıştır. B-2 sınıfı %97 doğruluk oranı ile yüksek bir başarı göstermiştir. B-52 sınıfı %93,4 doğruluk oranı ile 85 görseli doğru sınıflandırmış, bazı görseller C-130 ve C-5 sınıflarıyla karışmıştır. Gerçek sınıflardaki görseller ile ne kadar doğru sınıflandırıldığını gösteren en sağdaki sütunda oranların birçoğu %90'ın üzerindedir ve genelleme yeteneğinin yüksek olduğunu ortaya koymaktadır.

4.4. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Değerlendirilmesi

CNN-SVM modeline veri artırma işlemi uygulandıktan sonra elde edilen sonuçlar karşılaştırılmıştır. Farklı başlangıç öğrenme oranı, farklı optimizasyon algoritmaları ve epok sayıları değiştirilerek sonuçlar değerlendirilmiştir.

4.4.1. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde SGDM algoritmasının kullanılması

Veri artırma tekniği uygulanarak CNN modeli değerlendirilmiştir. Tablo 4.10.'da sgdm optimizasyon algoritması ile eğitilen CNN modelinin, farklı öğrenme oranları ve epok

sayıları değiştirilerek elde edilen doğrulama doğruluğu ve test doğruluğu değerleri ayrıntılı olarak analiz edilmiş ve hangi parametrelerin sabit kaldığı, hangilerinin değişken olduğu belirtilmiştir.

Tablo 4.10. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitiminde SGDM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc (%)	Test Acc.
10	0,001	sgdm	88,81	86,06%
20	0,001	sgdm	92,68	91,15%
30	0,001	sgdm	94,27	90,08%
40	0,001	sgdm	93,74	91,96%
50	0,001	sgdm	96,4	91,15%
60	0,001	sgdm	95,47	89,95%
70	0,001	sgdm	94,54	92,63%
80	0,001	sgdm	94,67	91,15%
90	0,001	sgdm	95,34	89,54%
100	0,001	sgdm	95,34	92,90%
10	0,0001	sgdm	79,89	86,33%
20	0,0001	sgdm	83,62	86,46%
30	0,0001	sgdm	89,61	88,20%
40	0,0001	sgdm	87,88	87,27%
50	0,0001	sgdm	88,02	85,66%
60	0,0001	sgdm	88,28	85,52%
70	0,0001	sgdm	91,74	89,14%
80	0,0001	sgdm	92,14	88,61%
90	0,0001	sgdm	92,01	90,21%
100	0,0001	sgdm	91,74	84,58%

Orta öğrenme oranı 0,001 ile eğitilen model, eğitim sürecinin başlarında (10 epok) yüksek bir başlangıç doğrulama doğruluğu (%88,81) ve test doğruluğu (%86,06) elde etmiştir. Epok sayısının 20'ye yükseltilmesiyle doğrulama doğruluğu belirgin bir artış göstererek %92,68'e çıkmış ve test doğruluğu da %91,15'e ulaşmıştır. 30 ve 40 epoklarda doğrulama doğruluğu sırasıyla %94,27 ve %93,74 ile yüksek performans göstermiştir; bu epoklarda test doğruluğu sırasıyla %90,08 ve %91,96 seviyelerinde gerçekleşmiştir. 50 epokta model, doğrulama doğruluğunda %96,4 ile maksimum değere ulaşmıştır. Ancak test doğruluğu %91,15 ile bu zirveyi tam olarak yansıtmamıştır. 60 ve 90 epok arasında doğrulama doğruluğu değerleri küçük dalgalanmalar ile %94-95 aralığında kalmıştır. Bu süreçte test doğruluğunda da dalgalanmalar gözlemlenmiş ve en yüksek test doğruluğu 70

epokta %92,63 olarak gerçekleşmiştir. 100 epok sonunda doğrulama doğruluğu %95,34 gibi yüksek bir değer alırken, test doğruluğu da %92,90 ile iyi bir seviyeye ulaşmıştır.

Düşük öğrenme oranı 0,0001 ile eğitilen model, eğitim sürecinin başlangıcında (10 epok) doğrulama doğruluğu %79,89 ve test doğruluğu %86,33 değerlerini elde ederek iyi bir başlangıç yapmıştır. Epok sayısının artırılmasıyla (20-30 epok arası) doğrulama doğruluğu bir yükseliş göstermiş ve 30 epok sonunda %89,61 değerine ulaşmıştır. Bu noktada test doğruluğu ise %88,20 ile yüksek seviyede gerçekleşmiştir. Epok sayısı 40, 50 ve 60 değerleri verildiğinde doğrulama doğruluğu %87-88 bandında sabit bir performans sergilemiştir, ancak test doğruluğu bu süreçte düşüş göstermiş ve 60 epokta %85,52'ye gerilemiştir. 70-100 epok arasında doğrulama doğruluğu genel olarak yüksek (%91-92 civarı) ve stabil hale gelmiştir. En yüksek doğrulama doğruluğu 80 epokta %92,14 iken, en yüksek test doğruluğu 90 epokta %90,21 olarak gerçekleşmiştir. Ancak, 100 epok sonunda test doğruluğunun (%84,58) belirgin bir düşüş göstermesi, modelin aşırı öğrenme eğilimine girdiğini ve genel performansın düştüğünü işaret etmektedir.

4.4.2. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde Adam algoritmasının kullanılması

Veri artırma tekniği uygulanarak CNN-SVM modeli değerlendirilmiştir. Tablo 4.11., Adam optimizasyon algoritması ile eğitilen CNN-SVM modelinin, farklı öğrenme oranları ve epok değerleri değiştirilerek elde edilen doğrulama doğruluğu ve test doğruluğu oranlarını göstermektedir.

Tablo 4.11. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitiminde ADAM Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu

Epoch	InitialLearnRate	trainingOptions	Validation Acc (%)	Test Acc.
10	0,001	Adam	86,55	86,46%
20	0,001	Adam	88,55	88,61%
30	0,001	Adam	91,21	89,68%
40	0,001	adam	93,87	92,36%
50	0,001	adam	91,34	91,29%
60	0,001	adam	93,74	92,49%
70	0,001	adam	93,34	91,96%
80	0,001	adam	95,61	93,30%
90	0,001	adam	95,07	93,97%
100	0,001	adam	93,48	92,76%
10	0,0001	adam	87,08	86,33%
20	0,0001	adam	92,41	88,74%
30	0,0001	adam	94,14	88,34%
40	0,0001	adam	94,67	89,14%
50	0,0001	adam	92,41	89,95%
60	0,0001	adam	94,81	89,54%
70	0,0001	adam	94,94	89,54%
80	0,0001	adam	94,41	90,08%
90	0,0001	adam	92,81	90,75%
100	0,0001	adam	96,14	91,02%

Orta düzey öğrenme oranı 0,001 ile eğitilen model, eğitim sürecinin başından itibaren istikrarlı bir artış göstermiştir. Başlangıçta (10 epok) doğrulama doğruluğu %86,55 iken test doğruluğu %86,46 seviyesindedir. Epok sayısı artıktıkça doğrulama ve test doğruluğunda düzenli bir artış gerçekleşmiştir. Özellikle 40 epok sonunda doğrulama doğruluğu %93,87, test doğruluğu ise %92,36 değerlerine ulaşarak yüksek performans elde edilmiştir. Epok sayısının 80'e ulaşmasıyla doğrulama doğruluğu %95,61, test doğruluğu %93,30 gibi çok yüksek değerlere ulaşmıştır. 90 epok sonunda doğrulama doğruluğu %95,07, test doğruluğu ise %93,97'dir. Ancak 100 epokta küçük bir düşüş yaşanarak doğrulama doğruluğu %93,48, test doğruluğu ise %92,76'ya gerilemiştir.

Düşük öğrenme oranı 0,0001 ile eğitilen model başlangıçtan itibaren doğruluk oranlarını kademeli olarak yükseltmiştir. İlk 10 epok sonunda doğrulama doğruluğu %87,08, test doğruluğu ise %86,33 seviyelerinde gerçekleşmiştir. Epok sayısının artırılmasıyla doğruluk oranları sürekli artış göstermiştir. Özellikle 30 epokta doğrulama doğruluğu %94,14'e kadar yükselmiş, test doğruluğu ise %88,34 seviyesine ulaşmıştır. 50 ve 70 epok arasında doğrulama doğruluğu sırasıyla %92,41 ve %94,94 gibi yüksek seviyelerde

gerçekleşmiş, test doğruluğu ise sırasıyla %89,95 ve %89,54 seviyelerinde kalmıştır. Eğitim sürecinin sonunda (100 epok) en yüksek doğrulama doğruluğu %96,14 ve test doğruluğu ise %91,02 seviyesindedir. Bu sonuçlar, düşük öğrenme oranının Adam optimizasyon algoritması ile tutarlı ve yüksek sınıflandırma performansına ulaştığını göstermektedir.

4.4.3. Veri artırma işlemi uygulanan CNN-SVM modelinin eğitiminde RMSprop algoritmasının kullanılması

Veri artırma tekniği uygulanarak CNN modeli değerlendirilmiştir. Tablo 4.12., RMSprop optimizasyon algoritması ile eğitilen CNN modelinin, farklı öğrenme oranları ve epok sayıları değiştirilerek elde edilen doğrulama doğruluğu ve test doğruluğu oranları gösterilmiştir. Hangi parametrelerin sabit kaldığı, hangilerinin değişken olduğu belirtilmiştir.

Tablo 4.12. Veri Artırma İşlemi Uygulanan CNN-SVM Modelinin Eğitimde RMSPROP Algoritmasının Kullanılması ile Elde Edilen Test Doğruluğu ve Doğrulama Doğruluğu Tablosu


Epoch	InitialLearnRate	trainingOptions	Validation Acc (%)	Test Acc.
10	0,001	rmsprop	85,75	85,52%
20	0,001	rmsprop	86,15	90,08%
30	0,001	rmsprop	93,08	88,61%
40	0,001	rmsprop	93,61	89,68%
50	0,001	rmsprop	91,61	90,08%
60	0,001	rmsprop	95,34	90,88%
70	0,001	rmsprop	95,87	92,90%
80	0,001	rmsprop	95,87	91,69%
90	0,001	rmsprop	95,74	93,03%
100	0,001	rmsprop	96,54	90,75%
10	0,0001	rmsprop	78,56	86,06%
20	0,0001	rmsprop	90,81	87,80%
30	0,0001	rmsprop	84,55	86,33%
40	0,0001	rmsprop	94,27	87,40%
50	0,0001	rmsprop	91,74	89,01%
60	0,0001	rmsprop	92,41	89,68%
70	0,0001	rmsprop	93,48	90,88%
80	0,0001	rmsprop	93,34	89,68%
90	0,0001	rmsprop	91,08	91,02%
100	0,0001	rmsprop	94,27	87,53%

Orta düzey öğrenme oranı 0,001 ile eğitilen modelin performansı ilk epoklardan itibaren oldukça yüksek değerler göstermiştir. Başlangıçta (10 epok) doğrulama ve test doğruluğu sırasıyla %85,75 ve %85,52 seviyesindedir. Epok sayısının artmasıyla birlikte model performansında istikrarlı artışlar gözlenmiştir. Özellikle 30 epok sonunda doğrulama doğruluğu %93,08, test doğruluğu ise %88,61 olarak ölçülmüştür. Epok sayısının 60 ile 100 arasındaki değerlerinde, doğrulama doğruluğu sürekli olarak %95'in üzerinde seyretmiş, test doğruluğu ise bu süreçte %90-93 arasında yüksek bir seviyede devam etmiştir. Özellikle 70 epok sonunda %95,87 doğrulama doğruluğu ve %92,90 test doğruluğu elde edilerek modelin performansı zirve noktasına ulaşmıştır. 100 epok değeri verildiğinde ise doğrulama doğruluğu %96,54 seviyesine ulaşırken test doğruluğu %90,75 olarak kaydedilmiştir.

Düşük öğrenme oranı 0,0001 ile gerçekleştirilen eğitim süreci, başlangıçtan itibaren tatmin edici doğruluk değerleri ortaya koymuştur. İlk olarak, 10 epok sonunda doğrulama doğruluğu %78,56 seviyesindeyken, test doğruluğu %86,06 oranındadır. Epok sayısının artırılmasıyla doğrulama doğruluğu önemli bir artış göstermiş, özellikle 40 epokta %94,27 gibi yüksek bir seviyeye ulaşmıştır. Ancak aynı noktada test doğruluğu %87,40 gibi daha düşük bir değerle sınırlı kalmıştır. Bu durum, doğrulama verisinde yüksek performans elde edilmesine rağmen modelin test verilerine genelleme yaparken zorlandığını göstermektedir. Epok sayısı 50-100 aralığında olduğunda, doğrulama doğruluğu değerleri genel olarak %91-94 arasında yüksek bir seviyede seyretmiş, test doğruluğu da %87-91 aralığında kalmıştır.


4.4.4. Veri artırma işlemi uygulanmış CNN-SVM modelinde elde edilen en yüksek test doğruluğunun analizi

CNN-SVM modeline veri artırma işlemi uygulandıktan sonra elde edilen en yüksek test doğruluğu oranını 90 epok, 0,001 başlangıç öğrenme oranı ve SGDM algoritmasıyla elde etmiştir. Test doğruluğu %93,97 ve doğrulama doğruluğu %95,07'dir.



Şekil 4.7 Veri Artırma İşlemi Uygulanmış CNN-SVM Modelinin En Yüksek Test Doğruluğuna Ait Eğitim Grafiği

Şekil 4.7'deki eğitim grafiği incelendiğinde eğitim doğruluğu ilk epoklarda hızlı bir şekilde artarak kısa sürede %90'ın üzerine çıkmış ve 10 epok sonunda %99 değerlerine yaklaşarak modelin veriyi iyi öğrendiğini göstermiştir. Doğrulama doğruluğu %95,07 seviyesinde sabitlenmiştir. Eğitim ve doğrulama doğruluğu arasındaki farkın düşük seviyelerde olması modelin aşırı öğrenme durumunda olmadığını ve yüksek bir genelleme kabiliyetine sahip olduğunu göstermektedir. Eğitim kaybı çok yüksek bir değerden başlayarak hızla düşmüş ve düşük seviyelerde sabitlenmiştir. Doğrulama kaybı da aynı şekilde yüksek seviyelerden başlayarak ilk epoklarda doğrudan düşüş göstermiştir. Doğrulama kaybının eğitim kaybına yakın olması, modelin doğrulama verileri üzerinde iyi bir performans ortaya koyduğunu ve aşırı uyum riskinin düşük olduğunu göstermektedir.



Şekil 4.8 Veri Artırma İşlemi Uygulanmış CNN-SVM Modelinin En Yüksek Test Doğruluğuna Ait Karışıklık Matrisi

Şekil 4.8'deki karışıklık matrisi incelendiğinde, B-1 sınıfına ait 93 görselden 89'u doğru tahmin edilmiş ve %95,7 doğruluk elde edilmiştir. B-2 sınıfında 100 görselin 97'si doğru sınıflandırılmış ve bu sınıf %97 ile en yüksek başarıya ulaşmıştır. B-52 sınıfı, C-135, C-130 ve C-5 sınıflarıyla karışmıştır. Buna rağmen doğruluk oranı %96,7'dir. C-135 sınıfında %84,8 doğruluk elde edilmiş, bu sınıfın 5 görseli diğer sınıflarla karışmıştır. Bu durum modelin bu sınıfı ayırt etmede zorlandığını göstermektedir. Genel olarak B-2, B-52 ve C-5 sınıflarında sınıflandırma doğruluğunun yüksek olduğu görülmektedir. C-135 ve KC-10 gibi bazı sınıflarda sınıf içi karışıklıkların daha fazla olduğu, görsel benzerliklerden dolayı hataların arttığı görülmektedir.

5. SONUÇ VE GELECEKTEKİ ÇALIŞMALAR

Shayan Khos tarafından oluşturulan veri seti ile yapılan bu çalışma, farklı sınıflandırma yöntemlerinde farklı sonuçlar elde etmiştir. Bu modelin pratik uygulamadaki performansını değerlendirmek için Shayan Khos dünya genelindeki hava üslerinden alınan görüntüler ile bu veri setini oluşturmuştur. Yapılan testlerde çalışmanın iki temel yeteneği analiz edilmek istenmiştir. İlk amacı uçak türünü tespit etme ve diğer amacı ise algılanan uçağın ait olduğu kategoriyi doğru bir şekilde belirleme yeteneğidir. Bu çalışmada temel olarak dört farklı durum sınıflandırma için karşılaştırılmıştır.

İlk aşamada tüm veri seti hem CNN modeline hem de CNN-SVM modeline uygulanmıştır. Sonraki aşamada da CNN ve CNN-SVM modellerine ayrı ayrı veri artırma işlemi uygulanarak karşılaştırmalar değerlendirilmiştir. Kullanılan CNN ve CNN-SVM sınıflandırma modellerinin, bazı uçak türlerini yanlış sınıflandırıp farklı kategoriye koyma eğiliminde olduğu gözlemlenmiştir.

Doğrudan CNN'e verildiğinde en yüksek test doğruluğu oranı %93,30 değeri elde edilmiştir. Parametreler değiştirilerek elde edilen %93,30'luk bu test doğruluğu oranı, 100 epok, 0,0001 başlangıç öğrenme oranı ve Adam algoritmasında görülmüştür. Şekil 4.1 ve Şekil 4.2'de bu teste ait karışıklık matrisi ve grafiği verilmiştir. Veri artırma işlemlerinden sonra doğrudan CNN'e verilen veri setinde en yüksek test doğruluğu %96,52 elde edilmiştir. Parametreler değiştirilerek elde edilen bu değer 80 epok, öğrenme oranı 0,001 ve SGDM algoritmasında görülmüştür. Eğitim grafiği, Şekil 4.3'te ve karışıklık matrisi Şekil 4.4'te verilmiştir. CNN-SVM modelinde ise en yüksek test doğruluğu oranı %92,23 olmuştur. Bu test doğruluğu oranına 80 epok, başlangıç öğrenme oranı 0,001 ve SGDM algoritmasında elde edilmiştir. Bu test doğruluğuna ait eğitim grafiği Şekil 4.5'te ve karışıklık matrisi Şekil 4.6'da verilmiştir. CNN-SVM modeline veri artırma işlemleri uygulandıktan sonra elde edilen test doğruluğu oranı %93,97 ile 90 epok, 0,001 başlangıç öğrenme oranı ve Adam algoritmasında gerçekleşmiştir. Eğitim grafiği Şekil 4.7'de ve karışıklık matrisi Şekil 4.8'de verilmiştir.

Tablo 5.1. Uçak Sınıflarının Kullanılan Modellere Göre Doğrulama Oranları

		B-1	B-2	B-52	C-130	C-135	C-5	E-3	KC-10
CNN	SGDM	100%	98,00%	91,20%	81,10%	79,3%	95,70%	95,70%	94,70%
	ADAM	95,70%	97,00%	86,80%	91,10%	83,70%	96,70%	98,90%	95,80%
	RMSPROP	95,70%	99,00%	74,70%	85,60%	78,30%	90,20%	97,90%	95,80%
CNN V.A.	SGDM	96,80%	99,00%	95,60%	96,70%	90,20%	94,60%	100%	98,90%
	ADAM	100,00%	99,00%	90,10%	96,70%	93,50%	95,70%	98,90%	95,80%
	RMSPROP	100,00%	98,00%	94,50%	93,30%	93,50%	96,70%	96,80%	96,80%
CNN-SVM	SGDM	94,60%	97,00%	93,40%	88,90%	85,90%	90,20%	95,70%	91,60%
	ADAM	94,60%	98,00%	83,50%	87,80%	82,60%	88,00%	98,90%	95,80%
	RMSPROP	97,80%	97,00%	80,20%	92,20%	79,30%	90,20%	95,70%	94,70%
CNN-SVM V.A.	SGDM	97,80%	94,90%	95,60%	83,30%	92,40%	87,00%	100%	91,60%
	ADAM	95,70%	98,00%	96,70%	92,20%	84,80%	96,70%	97,90%	89,50%
	RMSPROP	96,80%	98,00%	91,20%	90,00%	89,10%	91,30%	97,90%	89,50%

Tablo 5.2. Uçak Sınıflarının Modellere Göre Doğru Sınıflandırma Sayıları

		B-1	B-2	B-52	C-130	C-135	C-5	E-3	KC-10
CNN	SGDM	93	97	83	73	73	88	90	90
	ADAM	89	96	79	82	77	89	93	91
	RMSPROP	89	98	68	77	72	83	92	91
CNN V.A.	SGDM	90	98	87	87	83	87	94	94
	ADAM	93	98	82	87	86	88	93	91
	RMSPROP	93	97	86	84	86	89	91	92
CNN-SVM	SGDM	88	96	85	80	79	83	90	87
	ADAM	88	97	76	79	76	81	93	91
	RMSPROP	91	96	73	83	73	83	90	90
CNN-SVM V.A.	SGDM	91	94	87	75	85	80	94	87
	ADAM	89	97	88	83	78	89	92	85
	RMSPROP	90	97	83	81	82	84	92	85

Tablo 5.1. ve Tablo 5.2.'de çalışılan modellerin ve algoritmaların en yüksek test doğruluğu oranlarına göre uçak sınıfları bazında elde edilen değerler verilmiştir. Tablo 5.1.'de yüzdesel olarak, Tablo 5.2.'de görsel sayısı olarak belirtilmiştir.

Farklı yöntemlerin ve optimizasyon algoritmalarının kullanıldığı CNN ve CNN-SVM modellerinin, sınıflara göre yüzdesel doğru sınıflandırma oranlarını göstermektedir. Veriler, veri artırma (V.A.) işlemi yapılmış ve veri artırılmamış durumlar için ayrı ayrı karşılaştırmalı olarak sunulmuştur. CNN modelinin sonuçları incelendiğinde; veri artırımı yapılmadan elde edilen sonuçlarda özellikle B-1 sınıfı SGDM algoritması ile %100 doğruluk oranına ulaşmıştır. B-1, B-2, E-3 ve KC-10 sınıflarında genel olarak yüksek performans

gösterirken, C-135 sınıfında ise daha düşük oranlar gözlenmiştir. CNN modelinde veri artırımı (V.A.) yapıldığında sınıflandırma performanslarının önemli ölçüde arttığı dikkat çekmektedir. Özellikle RMSprop ve Adam algoritmaları ile B-1 sınıfında %100 doğruluk elde edilmiştir. Ayrıca SGDM algoritması ile E-3 sınıfında da %100 oranında yüksek performans yakalanmıştır. Diğer tüm sınıflarda veri artırımı genel olarak doğruluk oranlarını artırmıştır. CNN-SVM modelinde veri artırımı yapılmadığında sonuçların CNN modeline göre genellikle daha düşük veya yakın doğruluk oranlarına sahip olduğu görülmektedir. B-52 uçağı, Adam ve RMSprop algoritmaları kullanıldığında; C-130 uçağı ise Adam ve SGDM algoritmalarıyla eğitildiğinde, doğruluk oranları %80 ile %90 aralığında kalmış ve genel olarak CNN modelinin ortalama performansının altında bir başarı göstermiştir. CNN-SVM modelinde veri artırımı (V.A.) uygulandığında ise performans belirgin şekilde yükselmiştir. Özellikle E-3 sınıfında, SGDM algoritması kullanılarak %100 doğruluk oranına ulaşılmış; B-2 sınıfında ise Adam ve RMSprop algoritmaları ile %98 doğruluk oranı elde edilerek yüksek sınıflandırma başarıları gözlemlenmiştir. Bununla birlikte, veri artırımı yapılmış CNN-SVM modelinin sonuçları, veri artırma uygulanmış CNN modelinin sonuçlarına çok yakın olmakla birlikte, C-130 ve KC-10 sınıflarında daha düşük kalmıştır. Sonuç olarak, veri artırımı (V.A.) işleminin CNN ve CNN-SVM modellerinin performansını önemli ölçüde artırdığı açıkça görülmektedir. CNN modeli genel olarak CNN-SVM modeline göre daha iyi sonuçlar vermiştir. Optimizasyon algoritmaları arasında Adam ve SGDM algoritmaları, sınıflandırmada daha iyi performans göstermiştir.

SGDM optimizasyon algoritması, 0,001 başlangıç öğrenme oranı ve 80 epok değeri kullanılarak eğitilen CNN modeli üzerinde uygulandığında, %96,52 test doğruluğu ve %96,14 doğrulama doğruluğu ile bu çalışmanın en yüksek performansını ortaya koymuştur. Eğitim ve doğrulama grafikleri incelendiğinde, modelin hızlı ve etkili bir şekilde öğrendiği, doğrulama doğruluğunun kısa sürede yüksek değerlere ulaştığı ve stabil bir biçimde bu değerlerde seyrettiği gözlemlenmiştir. Karışıklık matrisi incelendiğinde ise sınıfların büyük çoğunluğunda oldukça yüksek doğruluk oranları sağlanmış, özellikle B-1, KC-10, B-2 gibi sınıflardaki yüksek doğruluk değerleri ile neredeyse tamamen doğru sınıflandırıldığı tespit edilmiştir.

Bu tez çalışmasının devamında yapılacak yeni araştırmalarda, performansın daha ileri seviyelere taşınması mümkündür. Öncelikle, sınıflandırma başarısını artırmak ve sınıflar arası karışıklığı minimize etmek için farklı veri artırma yöntemlerinin denenmesi faydalı olacaktır. Özellikle B-52 ve C-135 gibi sınıflarda oluşan düşük doğruluk oranlarının veri setindeki eksiklik veya sınıfların benzerliğinden kaynaklandığı düşünüldüğünde, daha

gelişmiş veri artırma teknikleri ile sınıflandırma doğruluğunun artırılması hedeflenebilir. Bunun yanında, kullanılan CNN mimarisinin daha derin ve karmaşık hale getirilmesi veya transfer öğrenme yöntemlerinin kullanılmasıyla eğitim sürecinin etkinliği artırılarak daha yüksek doğruluk oranlarına ulaşılması sağlanabilir. Yeni çalışmalarda farklı optimizasyon algoritmaları ve hiper parametre ayarlama yöntemlerinin sistematik olarak test edilmesi de önerilmektedir. Ayrıca, elde edilen yüksek performansın gerçek dünya uygulamalarında test edilmesi amacıyla daha kapsamlı ve çeşitli veri setleriyle modelin genelleme yeteneğinin doğrulanması gerekmektedir. Böylece, modelin gerçek hayatta karşılaşılabilecek durumlara karşı dayanıklılığı ve etkinliği artırılmış olacaktır. Son olarak, CNN tabanlı özellik çıkarımının ardından sınıflandırıcı olarak SVM dışında diğer makine öğrenmesi algoritmalarının performanslarının karşılaştırılmasıyla, sınıflandırma doğruluğunun ve kararlılığının geliştirilmesi sağlanabilir. Bu çalışmalar, derin öğrenme ve makine öğrenmesi tabanlı sınıflandırma yaklaşımlarının geliştirilmesine ve uçakların sınıflandırılması gibi kritik uygulamalarda daha etkili ve güvenilir sistemlerin oluşturulmasına olanak sağlayacağı düşünülmektedir.

KAYNAKLAR

- [1] “Wright brothers | Biography, Inventions, Hometown, Plane, & Facts | Britannica”. Eriřim: 10 Aralık 2024. [Çevrimiçi]. Eriřim adresi: [britannica.com/biography/Wright-brothers](https://www.britannica.com/biography/Wright-brothers)
- [2] Qichang Wu, Hao Sun, Xian Sun, Daobing Zhang, Kun Fu, ve Hongqi Wang, “Aircraft Recognition in High-Resolution Optical Satellite Remote Sensing Images”, IEEE Geosci. Remote Sens. Lett., c. 12, sy 1, ss. 112-116, Oca. 2015, doi: 10.1109/LGRS.2014.2328358.
- [3] A. Zhao vd., “Aircraft Recognition Based on Landmark Detection in Remote Sensing Images”, IEEE Geosci. Remote Sens. Lett., c. 14, sy 8, ss. 1413-1417, Aęu. 2017, doi: 10.1109/LGRS.2017.2715858.
- [4] Y. Zhang, H. Sun, J. Zuo, H. Wang, G. Xu, ve X. Sun, “Aircraft Type Recognition in Remote Sensing Images Based on Feature Learning with Conditional Generative Adversarial Networks”, Remote Sens., c. 10, sy 7, s. 1123, Tem. 2018, doi: 10.3390/rs10071123.
- [5] J. Zuo, G. Xu, K. Fu, X. Sun, ve H. Sun, “Aircraft Type Recognition Based on Segmentation With Deep Convolutional Neural Networks”, IEEE Geosci. Remote Sens. Lett., c. 15, sy 2, ss. 282-286, řub. 2018, doi: 10.1109/LGRS.2017.2786232.
- [6] F. Azam, A. Rizvi, W. Z. Khan, M. Y. Aalsalem, H. Yu, ve Y. B. Zikria, “Aircraft Classification Based on PCA and Feature Fusion Techniques in Convolutional Neural Network”, IEEE Access, c. 9, ss. 161683-161694, 2021, doi: 10.1109/ACCESS.2021.3132062.
- [7] A. Saeed, H. B. Atif, U. Habib, ve M. Bilal, “Remote Sensing Aircraft Classification Harnessing Deep Learning Advancements”, içinde 2023 18th International Conference on Emerging Technologies (ICET), Kas. 2023, ss. 50-55. doi: 10.1109/ICET59753.2023.10374700.

- [8] K. Karacan, T. Uyar, ve M. K. Öztürk, “GÖRÜNTÜ İŞLEME VE GÖZETİMLİ MAKİNE ÖĞRENME TEKNİKLERİYLE TİCARİ HAVA ARACI SINIFLANDIRMA”.
- [9] Shayan, S-Khos/Deep-Learning-for-Aircraft-Recognition. (05 Aralık 2024). Jupyter Notebook. Erişim: 10 Aralık 2024. [Çevrimiçi]. Erişim adresi: github.com/S-Khos/Deep-Learning-for-Aircraft-Recognition
- [10] “Military aircraft- UAVs, Drones, Autonomy | Britannica”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [britannica.com/technology/B-1-bomber-aircraft](https://www.britannica.com/technology/B-1-bomber-aircraft)
- [11] “B-2 Spirit”, Air Force. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [af.mil/About-Us/Fact-Sheets/Display/Article/104482/b-2-spirit/](https://www.af.mil/About-Us/Fact-Sheets/Display/Article/104482/b-2-spirit/)
- [12] “B-52 | Development, Specifications, & Combat History | Britannica”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [britannica.com/technology/B-52](https://www.britannica.com/technology/B-52)
- [13] “C-5 Galaxy | Lockheed Martin”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [lockheedmartin.com/en-us/products/c-5.html](https://www.lockheedmartin.com/en-us/products/c-5.html)
- [14] “C-130 History”, Lockheed Martin. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [lockheedmartin.com/en-us/products/c130/history.html](https://www.lockheedmartin.com/en-us/products/c130/history.html)
- [15] “KC-135 Stratotanker”, Air Force. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim Adresi: [af.mil/About-Us/Fact-Sheets/Display/Article/1529736/kc-135-stratotanker](https://www.af.mil/About-Us/Fact-Sheets/Display/Article/1529736/kc-135-stratotanker)
- [16] “E-3 AWACS (Sentry) Airborne Warning and Control System, US”, Airforce Technology. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [airforce-technology.com/projects/e3awacs/](https://www.airforce-technology.com/projects/e3awacs/)
- [17] “E-3 Sentry (AWACS)”, Air Force. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [af.mil/About-Us/Fact-Sheets/Display/Article](https://www.af.mil/About-Us/Fact-Sheets/Display/Article)
- [18] “KC-10 Extender”, Air Force. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [af.mil/About-Us/Fact-Sheets/Display/Article/104520/kc-10extender](https://www.af.mil/About-Us/Fact-Sheets/Display/Article/104520/kc-10extender)
- [19] “fullfile”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: [mathworks.com/help/matlab/ref/fullfile.html](https://www.mathworks.com/help/matlab/ref/fullfile.html)

- [20] “categorical”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: mathworks.com/help/matlab/ref/categorical.html
- [21] “imageDatastore”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: mathworks.com/help/matlab/ref/matlab.io.datastore.imagedatastore.html
- [22] “splitEachLabel”. Erişim: 06 Ocak 2025. [Çevrimiçi]. Erişim adresi: mathworks.com/help/matlab/ref/matlab.io.datastore.imagedatastore.spliteachlabel.html
- [23] “augmentedImageDatastore”. Erişim: 11 Aralık 2024. [Çevrimiçi]. Erişim adresi: mathworks.com/help/deeplearning/ref/augmentedimagedatastore.html
- [24] A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti, ve D. De, “Fundamental Concepts of Convolutional Neural Network”, içinde Recent Trends and Advances in Artificial Intelligence and Internet of Things, c. 172, V. E. Balas, R. Kumar, ve R. Srivastava, Ed., içinde Intelligent Systems Reference Library, vol. 172. , Cham: Springer International Publishing, 2020, ss. 519-567. doi: 10.1007/978-3-030-32644-9_36.
- [25] I. Goodfellow, Y. Bengio, ve A. Courville, Deep learning. içinde Adaptive computation and machine learning. Cambridge, Mass: The MIT press, 2016.
- [26] G. Hinton, “Neural Networks for Machine Learning”.
- [27] D. P. Kingma ve J. Ba, “Adam: A Method for Stochastic Optimization”, 30 Ocak 2017, arXiv: arXiv:1412.6980. doi: 10.48550/arXiv.1412.6980.
- [28] B. Schölkopf ve A. J. Smola, Learning with kernels: support vector machines, regularization, optimization, and beyond. içinde Adaptive computation and machine learning. Cambridge, Mass: MIT Press, 2002.
- [29] H. Lodhi, C. Saunders, J. Shawe-Taylor, N. Cristianini, ve C. Watkins, “Text Classification using String Kernels”.