



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME YÖNTEMİ İLE HAVAALANLARINDA PİSTE
YETKİSİZ GİRİŞ UYARI SİSTEMİ**

YÜKSEK LİSANS TEZİ

ÜMİT YEŞİLYURT

HAZİRAN

**DERİN ÖĞRENME YÖNTEMİ İLE HAVAALANLARINDA PİSTE
YETKİSİZ GİRİŞ UYARI SİSTEMİ**

Ümit YEŞİLYURT

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

Danışman

Dr. Öğr. Üyesi Ayşe AYDIN YURDUSEV

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2025

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Ümit YEŞİLYURT tarafından hazırlanan “**Derin Öğrenme Yöntemi İle Havaalanlarında Piste Yetkisiz Giriş Uyarı Sistemi**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğretim Üyesi Ayşe AYDIN YURDUSEV

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Başkan: Prof. Dr. Mahmut HEKİM

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Dr. Öğretim Üyesi Erhan BERGİL

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 20/06/2025

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

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

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

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

Ümit YEŞİLYURT

19.05.2025

DERİN ÖĞRENME YÖNTEMİ İLE HAVAALANLARINDA PİSTE YETKİSİZ GİRİŞ UYARI SİSTEMİ

(Yüksek Lisans Tezi)

Ümit YEŞİLYURT

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2025

ÖZET

Çok sayıda insan, ulaşım ve taşımacılık konusunda havaalanlarını yoğun bir şekilde kullanmaktadır. Bu sebeple gerek insan sayısındaki fazlalık gerekse trafik yoğunluğu, havaalanlarında potansiyel suç oluşumuna sebep olabilmektedir. Gelişen teknoloji ve güvenlik yönetimi stratejileri ile emniyet önlemleri artırılarak kaza ve saldırı ihtimali düşürülmeye çalışılmaktadır. Güvenlik sistemleri, terminal ve yolcuların izlenerek herhangi bir açığın ortaya konulması için kullanılmaktadır. Bu sistem sayesinde havaalanlarında gelişen veya gelişme ihtimali olan olaylar tespit edilmektedir. Havaalanı çevresinde, sınır ihlali, uçağın kalkış veya iniş esnasında piste girme girişiminde bulunan canlıların takip edilip önlenmesi gibi uygulamalar yapılmaktadır. Bu çalışmada, havaalanı güvenliği için önemli bir husus olan erken uyarı sistemleri üzerine odaklanılmaktadır. İnsan, nesne ve hayvan tespiti üzerine yoğunlaşarak havaalanı çevresinde olası tehditlerin engellenmesi amacıyla görüntü işleme yöntemleri kullanılmıştır. Çalışma iki uygulamadan oluşmaktadır. Bu sayede sınıf farklılığına göre çalışmanın sonuçları gözlemlenecektir. İlk uygulamada sınıf sayısı düşük tutulup çalışmanın başarımları gözlemlenmiştir. Bu uygulamada, insan, nesne (ağaç) ve hayvan (kedi) görüntüleri ile nesne tespiti ve sınıflandırma yapılarak belirlenen hayali sınır ile ihlal senaryoları test edilmiştir. Sınır ihlal senaryoları sonucunda, insan, nesne (ağaç) ve hayvan (kedi) görüntülerinin eğitilmesi ile oluşturulan test kümesi sonucuna göre başarı oranı ağaç için %99, insan için %94 ve hayvan (kedi) için %100 olarak elde edilmiştir. İkinci uygulamada ise sınıf sayısı artırılmıştır. Sınıf sayısına insan, nesne (ağaç) ve hayvan (kedi) görüntülerinin yanında inek ve keçi görüntüleri de dahil edilip nesne tespiti ve sınıflandırma yapılarak belirlenen hayali sınır ile ihlal senaryoları test edilmiştir. Sınır ihlal senaryoları sonucunda, insan, nesne (ağaç) ve hayvan (kedi, inek, keçi) görüntülerinin eğitilmesi ile oluşturulan test kümesi sonucuna göre başarı oranı nesne (ağaç) için %91, insan için %86, hayvan (kedi) için %84, hayvan (inek) için %89 ve hayvan (keçi) için %75 olarak elde edilmiştir.

Sayfa Adedi : 60

Anahtar Kelimeler : Erken Uyarı Sistemleri, Görüntü İşleme, Yapay zekâ, Derin öğrenme.

Danışman : Dr. Öğr. Üyesi Ayşe AYDIN YURDUSEV

UNAUTHORIZED RUNWAY ENTRY WARNING SYSTEM AT AIRPORTS USING DEEP LEARNING METHOD

(M.Sc. Thesis)

Ümit YEŞİLYURT

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2025

ABSTRACT

A large number of people make extensive use of airports for transportation and travel purposes. Consequently, both the high volume of individuals and the intensity of traffic can lead to the emergence of potential criminal activities within airport premises. In response, advancements in technology and the implementation of modern security management strategies have aimed to enhance safety measures and reduce the likelihood of accidents and attacks. Security systems are employed to monitor terminals and passengers, enabling the identification of possible vulnerabilities. Through such systems, incidents occurring or likely to occur at airports can be detected in advance. Around airport perimeters, various applications are implemented, such as monitoring and preventing border breaches or the intrusion of living beings onto the runway during aircraft takeoff or landing. This study focuses on early warning systems, which are an important issue for airport security. Image processing techniques have been utilized with a particular focus on the detection of humans, objects, and animals, in order to prevent potential threats around airport environments. The study consists of two applications. In this way, the results of the study will be observed according to class differences. In the first application, the number of classes was kept little and the success level of the study was observed. In this application, violation scenarios were tested with imaginary boundaries determined by object detection and classification with human, object (tree) and animal (cat) images. Based on the test dataset generated through the training of these classes, the success rates were obtained as 99% for trees, 94% for humans, and 100% for cats. In the second implementation, the number of classes was increased. In addition to humans, objects (trees), and animals (cats), images of cows and goats were also included. Object detection and classification were again performed, and virtual boundary intrusion scenarios were tested. According to the results obtained from the test dataset, which was formed using images of all these categories, the success rates were determined as 91% for trees, 86% for humans, 84% for cats, 89% for cows, and 75% for goats.

Page Number : 60

Key- Words : Early warning systems, Image processing, Artificial intelligence,
Deep learning.

Supervisor : Dr. Öğr. Üyesi Ayşe AYDIN YURDUSEV

ÖN SÖZ VE TEŞEKKÜR

Yüksek Lisans Tezi olarak sunduğum “Havaalanları Güvenlik Uyarı Sistemleri” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Yüksek lisans öğrenimimde bana yol gösteren, destek veren ve katkılarını esirgemeyen tez danışmanım Dr. Öğr. Üyesi Ayşe AYDIN YURDUSEV’e teşekkür ederim.

Çalışmam boyunca bana maddi manevi desteğini esirgemeyen ve sabır gösteren eşime ve aileme teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	v
ÖN SÖZ VE TEŞEKKÜR	vi
İÇİNDEKİLER.....	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ.....	x
RESİMLER DİZİNİ.....	xi
KISALTMALAR DİZİNİ	xii
1. GİRİŞ.....	1
1.1. Havaalanı Güvenliği	2
1.1.1. Havaalanı Terminal Güvenliği	4
1.1.2. Havaalanı Çevre Güvenliği	6
1.1.3. Havaalanında Kullanılan Güvenlik Sistem ve Cihazlar	7
1.1.3.1. Kapı ve El Tipi Metal Arama Dedektörü.....	8
1.1.3.2. X-Ray Bagaj Arama Cihazı.....	8
1.1.3.3. Patlayıcı Tespit Sistemleri (EDS).....	9
1.1.3.4. Kartlı Geçiş Kontrol Sistemi (CACS).....	9
1.1.3.5. Biyometrik Sistemler.....	10
1.1.3.6. Kapalı Devre TV Sistemleri (CCTV).....	10
1.1.4. Havaalanı Çevre Güvenliğinde Kameranın Rolü	10
2. İLİŞKİLİ ÇALIŞMALAR	13
3. PROBLEM TANIMI VE ÖN-BİLGİ	16

	Sayfa
3.1. Problemin Durumu.....	16
3.2. Araştırmanın Amacı.....	16
4. MATERYAL VE YÖNTEM.....	17
4.1. Veri Seti	17
4.2. Derin Öğrenme.....	21
4.3. Evrişimli Sinir Ağları (CNN: Convolutional Neural Network)	23
4.3.1. Giriş katmanı (Input Layer).....	24
4.3.2. Evrişim Katmanı (Convolution Layer).....	25
4.3.3. Aktivasyon katmanı (Activation Layer).....	25
4.3.4. Havuzlama katmanı (Pooling Layer).....	26
4.3.5. Tam bağlı katman (Fully Connected Layer).....	26
4.3.6. Sadeleştirme katmanı (Dropout Layer).....	27
4.4. YOLO (You Only Look Once).....	27
4.5. YOLOv10 Sürümü.....	30
4.6. Performans Metrikleri.....	33
4.6.1. Karışıklık Matrisi.....	33
5. BULGULAR VE TARTIŞMA.....	37
6. SONUÇ.....	51
KAYNAKLAR.....	53
ÖZGEÇMİŞ.....	60

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 4. 1. Çalışma için kullanılan Eğitim ve Test Küme Sayıları (1. Uygulama)....	18
Çizelge 4. 2. Çalışma için kullanılan Eğitim ve Test Küme Sayıları (2. Uygulama).....	21
Çizelge 4. 3. İkili sınıflandırma için karışıklık matrisi	34



ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 4. 1. Çalışmanın iş akış diyagramı	18
Şekil 4. 2. Çalışmada kullanılan pusedo code	20
Şekil 4. 3. Evrişimli Sinir Ağı Mimarisi (CNN)	24
Şekil 4. 4. YOLOv10 Ağ Mimarisi.....	31
Şekil 5. 1. F1 Skoru - Güven Eğrisi (1.Uygulama)	37
Şekil 5. 2. Kesinlik Eğrisi (1. Uygulama)	38
Şekil 5. 3. Duyarlılık Eğrisi (1. Uygulama).....	38
Şekil 5. 4. Kesinlik - Duyarlılık Eğrisi (1. Uygulama).....	39
Şekil 5. 5. YOLOv10 modeline ait karışıklık matrisi (1. Uygulama).....	39
Şekil 5. 6. Test veri setindeki tahmin ve katman görüntüleri (1. Uygulama).....	41
Şekil 5. 7. Oxford sokağı analiz sonuçlarına ait görüntü kesiti	42
Şekil 5. 8. YOLOv10 eğitim sonuçları (1. Uygulama)	44
Şekil 5. 9. F1 Skoru - Güven Eğrisi (2. Uygulama)	44
Şekil 5. 10. Kesinlik Eğrisi (2. Uygulama)	45
Şekil 5. 11. Duyarlılık Eğrisi (2. Uygulama).....	45
Şekil 5. 12. Kesinlik - Duyarlılık Eğrisi (2. Uygulama).....	46
Şekil 5. 13. YOLOv10 modeline ait karışıklık matrisi (2. Uygulama).....	47
Şekil 5. 14. Test veri setindeki tahmin ve katman görüntüleri (2. Uygulama).....	48
Şekil 5. 15. İnek görüntülerinin yer aldığı analiz sonuçlarına ait görüntü kesiti	49
Şekil 5. 16. Keçi görüntülerinin yer aldığı analiz sonuçlarına ait görüntü kesiti.....	49
Şekil 5. 17. YOLOv10 eğitim sonuçları (2. Uygulama).....	50

RESİMLER DİZİNİ

Resim	Sayfa
Resim 1. 1. İstanbul Havaalanı dıştan görünüm.....	4
Resim 1. 2. İstanbul Havaalanı Terminali (İç kısım).....	5
Resim 1. 3. Mardin Prof. Dr. Aziz Sancar Havaalanı Çevre Güvenlik Sınırı.....	7
Resim 4. 2. Yapay zekanın gelişim süreci.....	22
Resim 4. 3. YOLO'nun genel çalışma prensibi.....	29



KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı kısaltmalar yanda açıklamaları verilmek üzere aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ANN	Artificial Neural Networks
CACS	Card Access Control System
CCTV	Close Circuit Television
CNN	Convolutional Neural Networks
Colab	Colaboratory
DL	Deep Learning
Doc	Document
DVM	Destek Vektör Makineleri
EASA	European Aviation Safety Agency
ECAC	European Civil Aviation Conference
EDS	Explosive Detection System
FAA	Federal Aviation Administration
FOD	Foreign Object Damage
IATA	International Air Transport Association
ICAO	International Civil Aviation Organization
IDE	Integrated Development Environment
IoU	Intersection over Union
İHA	İnsansız Hava Araçları
mAP	Mean Average Precision

ML	Machine Learning
MÜKDN	Marmara Üniversitesi Kriminal Davranış/Nesne Veri Seti
OpenCV	Open Source Computer Vision Library
PSA	Partial Self-Attention
RCNN	Regions with Convolutional Neural Networks
ReLU	Rectified Linear Unit
RT-DETR	Real Time Detection Transformer
Sc Down	Spatial Channel Decoupling Downsampling
SHGM	Sivil Havacılık Genel Müdürlüğü
SPPF	Spatial Pyramid Pooling Fast
SSD	Single Shot Detector
TSA	Transportation Security Administration
YOLO	You only look once

1. GİRİŞ

Havaalanları, sivil havacılık altyapısının temel unsurlarından biri olarak; yolcu ve kargo taşımacılığına yönelik operasyonel faaliyetlerin gerçekleştirildiği, aynı zamanda ekonomik kalkınma, ulusal güvenlik ve stratejik ulaşım planlaması açısından kritik öneme sahip kompleks yapılardır.

Modern hava taşımacılığı sisteminde havaalanları, sadece uçuşların gerçekleştirildiği fiziksel alanlar değil; hava trafik yönetimi, yer hizmetleri, gümrük işlemleri, acil durum yönetimi ve çok katmanlı güvenlik uygulamalarının entegre biçimde işletildiği kompleks merkezler olarak değerlendirilmektedir (IATA, 2023). Artan hava trafiği ve güvenlik riskleri doğrultusunda, havaalanı yönetiminde ileri teknolojilere dayalı çözümler, özellikle yapay zekâ destekli video analiz sistemleri, biyometrik tanımlama, otomatik bagaj tarama ve gerçek zamanlı tehdit algılama sistemleri gibi uygulamalar yaygın olarak benimsenmektedir (Özdemir ve Yıldız, 2021).

Havaalanları, aynı zamanda ülkenin sınır güvenliği açısından da stratejik rol oynamakta olup, hava yolu giriş çıkış noktaları üzerinden gerçekleştirilebilecek yasa dışı faaliyetlerin önlenmesine yönelik çok yönlü güvenlik protokolleri geliştirilmektedir (EASA, 2020). Ayrıca, havaalanlarının bulunduğu coğrafi konum, bölgesel kalkınma ve uluslararası bağlantılılık açısından da belirleyici bir unsur olmakta; bu yönüyle havaalanları yalnızca ulaştırma altyapısı değil, aynı zamanda ekonomik büyüme ve toplumsal etkileşim için kritik merkezler olarak işlev görmektedir (Kaya ve Demirtaş, 2019).

Havaalanları, yalnızca bir prestij göstergesi olmakla kalmayıp aynı zamanda ülke ekonomisine önemli katkılar sunan yapılar olduğundan, bu alanlarda güvenlik hizmetlerinin etkin bir şekilde sağlanması büyük bir önem taşımaktadır. Yapılacak ufak bir hata eylemlerinin sonuçlarını arttırdığı için havaalanları güvenlik alanında geçmişten günümüze cazip alanlar olmuştur (Yıldız vd., 2023).

1.1. Havaalanı Güvenliği

Havaalanı güvenliği, potansiyel tehdit unsurlarının ve tehlikeli durumların ortaya çıkmasını ya da ülkeye girişini önlemeye yönelik olarak yapılandırılmış çok katmanlı bir güvenlik sistemidir. Güvenlik uygulamalarının etkinliği, yasa dışı maddelerin, tehdit oluşturan kişilerin veya unsurların havaalanı sahasına ve uçaklara erişim ihtimalini büyük ölçüde azaltmaktadır. Bu bağlamda, havaalanı güvenliğinin temel amaçları; havaalanı altyapısını ve ulusal sınırları olası tehditlerden korumak, yolcu güvenliğini sağlamak ve toplumsal güvenlik algısını güçlendirmektir. Havacılık güvenliğine yönelik tehditler çok boyutludur. Bu tehditler; insan kaynaklı eylemler başta olmak üzere çevresel faktörler, olumsuz hava koşulları ve doğal afetler gibi çeşitli unsurlardan kaynaklanabilmektedir.

Havacılık sektöründe güvenliğin ne kadar önemli olduğu 1968-1972 yıllarında yapılan 364'ten çok uçak kaçırma olayıyla daha net görülmüştür (Çoban ve İpek, 2020). 1960'lı senelerin sonlarından başlayarak havaalanları ve sivil havacılık siyasi amaçlara yönelik suçların hedefi olmuştur (Abeyratne, 1994). Fakat bütün dünyada sivil havacılık için tehdit oluşturan kanun dışı fiillerin türü zaman içinde değişmiştir. 1970'li senelerde uçakların kaçırılması 1980 ve 1990'lı senelerde uçakların bombalanması en önemli tehditken, 2000'li senelerde söz konusu tehditlerin yönünü değiştirip bilgisayarlara bağlı havacılık bilgi sistemlerini hedef aldığı görülmüştür (Küçükönal, 2001). Yasadışı fiiller senelerdir ciddi bir tehlikeye dönüştüğünden alınacak tedbirlerin devamlılığı ile milletlerarası sivil havacılığın kanun dışı eylemlere karşı korunması gerekmektedir (Young, 2003).

Havacılık sektöründeki eylemlerde oluşan can kayıpları aynı zamanda hava taşımacılığının engellenmesiyle oluşan negatif iktisadi etkiler kritik bir hale gelmiştir. Eylemlerin engellenme becerisi ise tüm sistemdeki güvenlik önlemlerinin arttırılmasına bağlıdır (Button vd., 2004). Havaalanı yönetiminin, çalışanlar ile yolcuların güvenliğini temin etmenin yanı sıra bina, uçak ve başka ekipmanları da en iyi seviyede korunmasını sağlaması veya bunu temin edecek tedbirleri alması gerekmektedir. Fakat alınacak güvenlik tedbirleri hava taşımacılığının kritik bir avantajı olan hız etkenini yok etmeyecek biçimde olmalıdır (Wells ve Young 2011).

Kanun dışı fiillerin başlangıç noktası olması nedeniyle, havaalanları milletlerarası standartlara sahip güvenlik tedbirlerinin alınması gereken yerlerdir. Yolcu terminali binası

da kanun dışı fiilleri engellemek üzere güvenlik tedbirlerinin uygulanabileceği en kritik mekanlardan biridir. Bir havaalanı güvenlik faaliyetinin tam anlamıyla icra edilmesi; merkezi ve mahalli idarenin, havaalanı otoritelerinin, buralarda faaliyette bulunan başka şirketlerin, polis ve güvenlik personeliyle toplumun iş birliğini ve kararlılığını gerekli kılmaktadır (Frederickson ve LaPorte, 2002).

Hava meydanlarına yönelik çeşitli sabotaj eylemleri bulunmaktadır. Örneğin saldırı yapan insanın kolay bir biçimde olay yerinden uzaklaşmasına neden olacak birçok yöntem bulunmaktadır (Lykou vd., 2020). Sabotaj eylemleri arasında el çantası ve bavul gibi yerlere patlayıcı yerleştirilmesi, silah veya başka nesneyle ateş edilmesi ve uçağa patlayıcı maddelerin veya silahların sokulması sayılabilir (Küçükönel, 2001).

Güvenlik sisteminde aksaklıklara mahal vermemek, huzuru ve işleyişi sağlamak amacıyla güvenlik birimlerinin özenli ve dikkatli olmaları gerekmektedir (Karakuş, 2006). Havaalanları gün boyunca birçok kişiye aktif olarak hizmet verdiği için güvenlik sistemleri 24 saat çalışır vaziyette olmalıdır. Ayrıca havaalanı etrafının kontrol edilmesi, uçakların, havaalanı tesisleriyle binalarının, havaalanına dışardan gerçekleştirilebilecek saldırılar karşısında korunmasına yönelik olarak çok kritiktir (Küçükönel, 2001). Söz konusu kontrol, havaalanının etrafının nöbetçilerce devriye gezilmesi, gözetleme noktalarıyla kapalı devre TV sistemlerinden izlenilmesiyle yapılmaktadır (Tiryaki, 2013).

Bunun yanı sıra uçağın yaklaşmayla kalkış yollarının etrafı, ormanlık alanlarla araç park alanları gibi sabotajcıların kolayca gizlenebilecekleri yerlere özel ihtimam gösterilmelidir (Sochor, 1991). Havaalanı güvenliği, her iki yanında 3,04 m boş bir saha olan tel örgülerde başlamaktadır. Tel örgüler veya güvenlik bariyerleri ışıklandırılmalı, söz konusu engeller gizli bir biçimde geçildiğindeyse bu durumu ortaya koyacak ikaz cihazları kullanılmalıdır (Wells ve Young, 2011).

Ayrıca havaalanı çevre güvenliği, kontrol noktalarındaki güvenlik personelinin artırılmasıyla ve kamera sisteminin sınır hattı boyunca konumlandırılmasıyla hava tarafına giren kişilerin kolaylıkla tespit edilmesi sağlanmalıdır (Pütz, 2012).

Havaalanı güvenlik yönetiminde kullanılabilecek en önemli unsurlar teknoloji ve insandır. Tek başına teknoloji yeterli olmayıp ancak insan ile tamamlandığı zaman bir anlam

kazanmaktadır (Gemici ve Yılmaz, 2019). Bundan dolayı havaalanının güvenlik yönetiminde faydalanan bütün kaynakların aktif ve uyumlu bir biçimde çalıştırılması oldukça önemlidir (Arcúrio vd., 2020).

Teknolojik ilerlemelerle birlikte havaalanı güvenliği yeni bir boyut kazanarak terminal ve çevre güvenliği olarak ikiye ayrılmaktadır (Davis ve Chang, 2012). Terminal bölümü, yolcuların uçağa iniş-biniş yaptığı ve valizlerinin teslim edildiği yerdir. Çevre güvenlik bölümü ise havaalanı sınır hattı boyunca çevreleyen terminal dışında kalan yerleri içermektedir. Resim 1.1’ de İstanbul havaalanına ait bir görsel yer almaktadır.



Resim 1. 1. İstanbul Havaalanı dıştan görünüm.

1.1.1. Havaalanı Terminal Güvenliği

Havaalanı terminalleri, Resim 1.2’de görüldüğü üzere yolcu taşımacılığı süreçlerinin merkezinde yer alan, karmaşık operasyonel faaliyetlerin gerçekleştiği çok işlevli yapılardır. Bu binalar; biletleme, bagaj işlemleri, güvenlik kontrolleri, pasaport ve gümrük denetimleri, bekleme salonları ve uçağa biniş kapıları gibi çeşitli hizmet alanlarını bünyesinde barındırmaktadır.

Havaalanı terminal tasarımında temel hedef, yüksek yolcu yoğunluğuna uygun bir sirkülasyonun sağlanması, yolcu deneyiminin iyileştirilmesi ve tüm operasyonel süreçlerin

maksimum verimlilikle yürütülebileceği bir altyapının oluşturulmasıdır. Son yıllarda terminal planlamasında dijitalleşme ön plandadır; biyometrik geçiş sistemleri, temassız kontrol noktaları ve yapay zekâ tabanlı yönlendirme teknolojileri yaygın olarak kullanılmaktadır (IATA, 2023). Bununla birlikte, havaalanı terminalleri, sivil havacılık güvenliğinin en kritik bileşenlerinden birini oluşturmaktadır.

Terminal güvenliği; yolcu ve bagaj tarama sistemleri, kimlik doğrulama prosedürleri, patlayıcı madde tespit sistemleri, kapalı devre televizyon (CCTV) sistemleri, erişim kontrol üniteleri ve eğitilmiş güvenlik personeli ile çok katmanlı bir yapıda organize edilmektedir (EASA, 2020; Özdemir ve Yıldız, 2021).

Uluslararası güvenlik standartlarına (örneğin ICAO Annex 17 ve ECAC Doc 30) uyum, terminal alanlarındaki güvenlik protokollerinin temel çerçevesini oluşturmaktadır. Aynı zamanda, artan yolcu trafiği ve gelişen tehdit senaryoları doğrultusunda, terminal güvenliğinde proaktif yaklaşımlar ve gerçek zamanlı risk analizleri daha fazla önem kazanmaktadır (Graham, 2020). Terminal içi güvenliğin etkin yönetimi, yalnızca havaalanı operasyonlarının sürekliliği açısından değil, aynı zamanda yolcuların güven algısının korunması ve ülke güvenliği açısından da stratejik bir role sahiptir.



Resim 1. 2. İstanbul Havaalanı Terminali (İç Kısım)

1.1.2. Havaalanı Çevre Güvenliği

Havaalanı çevre güvenliği, sivil havacılık tesislerinin dış sınırlarının izinsiz giriş, sabotaj, casusluk, terör saldırısı ve diğer yasa dışı faaliyetlere karşı korunmasını amaçlayan kritik bir güvenlik alt sistemidir. Bu kapsamda çevresel güvenlik; tel örgüler, hareket ve titreşim algılayıcı sensörler, gece-gündüz çalışabilen termal kameralar, radar tabanlı izleme sistemleri ve insansız hava aracı (İHA) tehditlerine karşı geliştirilen karşı tedbir sistemleriyle desteklenmektedir (EASA, 2020).

Güvenlik açıklarının büyük bölümü genellikle havaalanı sınır hattında başladığından, çevre güvenliği sadece fiziksel bariyerlerle değil, aynı zamanda yapay zekâ destekli video analiz sistemleri ve entegre alarm yönetim altyapısı ile sürekli izlenmek zorundadır (Özdemir ve Yıldız, 2021). Çevre güvenliği arasında; sınır ihlali, uçak iniş kalkışı ve bu esnada piste girme girişiminde bulunan canlıların takip edilmesi gibi çalışmalar bulunmaktadır. Bunun gibi ihlallerinin önlenmesi için havaalanı sınır hattı boyunca çevre güvenlik kamera sistemi konumlandırılmaktadır. Bu sayede tüm ihlaller izlenerek gerekli müdahaleler yapılmaktadır (Topak vd., 2015; Shang vd., 2023).

Özellikle pist çevresine ve uçuş hattına yakın alanlarda meydana gelebilecek izinsiz insan ya da araç girişleri, uçuş emniyeti açısından ciddi riskler doğurabilmektedir. Bu nedenle, çevre güvenliği sistemleri yalnızca hırsızlık ya da sızma girişimlerini değil, aynı zamanda pist üzerindeki yabancı cisim tehlikesi (FOD) ve hayvan girişleri gibi operasyonel riskleri de önlemeye yönelik olarak planlanmaktadır (FAA, 2021). Bu bölümde pistin güvenli bir konumda kalmasını, olası tehditlerin piste ulaşmadan bu bölümde fark edilip tehditlerin önlenmesi amaçlanmaktadır (Willemsen ve Cadee, 2018).

Ancak çevre güvenliğinin yalnızca teknolojik altyapılarla sağlanması yeterli olmayıp bu sistemlerin etkin bir şekilde işletilebilmesi için insan faktörü kritik bir rol oynamaktadır. Güvenlik sistemlerinin işleyişinden sorumlu personelin, belirlenmiş prosedürlere hâkim olması, düzenli olarak eğitilmesi ve olası acil durum senaryolarına karşı hazırlıklı bulunması gerekmektedir. Nitelikli ve eğitilmiş insan kaynağı, çevre güvenlik sistemlerinin başarısını doğrudan etkileyen temel bileşenlerden biridir.

Çevresel güvenliğin yönetimi, uluslararası sivil havacılık güvenlik düzenlemeleri (örneğin

ICAO Annex 17 ve ECAC Doc. 30) ile uyumlu şekilde yürütülmekte ve havaalanı güvenlik yönetim sisteminin ayrılmaz bir parçası olarak konumlandırılmaktadır. Resim 1.3'te Google Earth üzerinden alınmış Mardin Prof. Dr. Aziz Sancar Havaalanının çevre güvenlik sınırı gösterilmektedir (kırmızı hat boyunca).



Resim 1. 3. Mardin Prof. Dr. Aziz Sancar Havaalanı Çevre Güvenlik Sınırı

1.1.3. Havaalanında kullanılan Güvenlik Sistem ve Cihazlar

Yasadışı faaliyetlerin artış göstermesi, havalimanlarında yolcu ve bagaj tarama sistemlerinin yaygın biçimde konuşlandırılmasını zorunlu kılmıştır (Skorupski ve Uchronski, 2015). Bu yüksek teknolojiye sahip tarama altyapıları, özellikle terör eylemleri başta olmak üzere yasa dışı girişimlerin hem ulusal hem de uluslararası düzeyde engellenmesine ve risklerin en aza indirilmesine olanak tanımaktadır. (Feng, 2007).

Bu bölümde, Türkiye’de yer alan havaalanlarında güvenlik hizmetlerinin yürütülmesinde önemli rol oynayan sistem ve cihazlara odaklanılmaktadır. Yolcuların bagaj arama ve tarama süreçlerinde aktif olarak kullanılan güvenlik teknolojileri; risklerin önceden belirlenmesi, tehlikeli maddelerin tespiti ve genel yolcu güvenliğinin sağlanması açısından kritik öneme sahiptir. Gelişen teknolojilerle birlikte bu cihazlar, yalnızca tarama işleviyle sınırlı kalmayıp bütüncül bir güvenlik yönetimi yaklaşımına katkı sağlayacak şekilde entegre sistemler olarak kullanılmaktadır.

1.1.3.1. Kapı ve El Tipi Metal Arama Dedektörü

Elektromanyetik alan ilkeleri doğrultusunda işleyen kapı ve el tipi metal dedektörleri, yolcu arama ve tarama uygulamalarında yaygın biçimde tercih edilen başlıca güvenlik sistemlerindendir (Singh ve Singh, 2003). Kapı tipi metal arama dedektörleri, metal ve metal içeren nesnelerin hacim ve kütle parametrelerine duyarlı biçimde elektromanyetik sinyaller üreterek alarm veren, geçit çerçevesi biçimde tasarlanmış güvenlik cihazlarıdır. Bu sistemler, güvenlik kontrol noktalarının yanı sıra gerekli görülen diğer alanlarda kişilerin güvenlik arama ve taramalarını gerçekleştirmek amacıyla yaygın olarak kullanılmaktadır (SHGM, 2015).

El tipi metal arama dedektörleri, havaalanlarında bireylerin üzerlerinde taşıyabilecekleri silah, bıçak gibi kesici-delici nesnelerin saptanmasına yönelik olarak; özellikle kapı tipi dedektörlerin tetiklediği alarmın kaynağının tam olarak belirlenemediği durumlarda, hedef bölgeye odaklanan tamamlayıcı bir arama-tarama aracı olarak kullanılmaktadır (Hallowel, 2001).

1.1.3.2. X-Ray Bagaj Arama Cihazı

X-ray bagaj arama cihazı, bagaj ve diğer eşyaların içindeki nesnelerin saptanmasına olanak tanıyan, yüksek enerjili x-ışınları kullanan gelişmiş bir güvenlik aygıtıdır. Farklı malzeme yoğunluklarını ayırt ederek operatörlerin monitörler üzerinden analiz edebileceği ayrıntılı görüntüler üretir (SHGM, 2015). X-ray bagaj arama cihazı, havaalanlarında bagaj ve eşya denetiminde birincil öneme sahip güvenlik teknolojileri arasında konumlandırılmaktadır (Küçükönel, 2001). Metal arama dedektörleri yalnızca metal bileşen içeren nesnelere karşı duyarlılık gösterdiğinden, havacılık güvenliğini tehdit edebilecek ancak metal içermeyen tehlikeli maddelerin tespiti konusunda yetersiz kalabilmektedir. Bu tür maddelerin algılanması ise x-ray bagaj arama cihazlarıyla sağlanmaktadır.

X-ray bagaj arama cihazı, başta yolcuların kabin içine taşıyabildiği bagajların denetlenmesinde kullanılmakla birlikte, uçak kargo bölmesine yerleştirilen alt bagajların incelenmesinden de etkin biçimde görev yapmaktadır. Tarama sürecine sağladığı operasyonel kolaylıklara karşın, yerleşik otomatik tehdit tanıma modülü bulunmadığından, operatörün uzmanlığına ve dikkat düzeyine bağlıdır (Shanks ve Bradley, 2004).

Türkiye’de uçuş güvenliği ve havacılık emniyetini riske atabilecek unsurların belirlenmesi amacıyla kullanılan x-ray bagaj arama cihazları, dış hatlardan gelen yolcuların terminal sahalarında da ülkeye sokulması yasak veya gümrük muafiyeti dışında kalan eşyaların denetlenmesinde etkin biçimde görev yapmaktadır.

1.1.3.3. Patlayıcı Tespit Sistemleri (EDS: Explosive Detection System)

Patlayıcı Tespit Sistemleri bagaj güvenliğinde çok katmanlı bir tarama zinciri sunmaktadır. Uçağa yükleme öncesinde her bagaj sırasıyla x-ray bagaj arama cihazı, bilgisayarlı tomografi ve iz dedektörleri aşamalarından geçirilmektedir. İlk kademede x-ray bagaj arama cihazları bagajları otomatik olarak değerlendirir; “temiz” olarak sınıflandırılanlar doğrudan uçağa yönlendirilirken “şüpheli” görülenler ileri inceleme amacıyla tomografi cihazına sevk edilir. Tomografi cihazında kesitsel görüntüleri elde edilen bagajlar, yetkili güvenlik personeli tarafından tekrar analiz edilir. Riskin bertaraf edilmediği vakalarda bagajlar kimyasal iz analizinin yapıldığı iz dedektörlerine aktarılır. İz dedektörü sonucunda da şüphe giderilmezse, bagaj sahibinin nezaretinde manuel arama prosedürü başlatılır; yolcu refakatinin mümkün olmadığı hallerde ise fiziki kontrol, yetkili personel tarafından bağımsız şekilde gerçekleştirilir (Shanks ve Bradley, 2004; Kraemer vd., 2009; Rekiel ve Wit, 2013; SHGM, 2015).

1.1.3.4. Kartlı Geçiş Kontrol Sistemi (CACS: Card Access Control System)

Havaalanı personeline tahsis edilen erişim kartları, çalışanların yetkilendirildikleri güvenlik bölgelerine giriş-çıkışlarını kolaylaştırmak ve yetkisiz erişimi önlemek amacıyla geliştirilmiştir (SHGM, 2009). Kartlı geçiş kontrol altyapısında, kısıtlı alanların girişlerine kart okuyucularla entegre turnike, otomatik bariyer ve benzeri fiziksel engeller yerleştirilerek izinsiz geçiş olasılığı en aza indirilmektedir (Uzuner, 2003). Personele tahsis edilen giriş kartı, kapı üzerindeki okuyucuya tanıtıldığında ilgili kapı mekanizması açılmakta ve işlem veri tabanına kaydedilmektedir. Her ne kadar yöntem pratik ve maliyet etkin olsa da kart paylaşımı gibi suistimal olasılıkları, yetkisiz kişilerin korunan bölgelere erişim riskini tamamen ortadan kaldıramamaktadır (Sayın, 2011). Bu nedenle, söz konusu sistemin etkinliği büyük ölçüde kapalı devre kamera sistemleri (CCTV) başta olmak üzere, diğer tamamlayıcı güvenlik önlemleriyle entegre edilerek artırılabilir.

1.1.3.5. Biyometrik Sistemler

Geniş bir kullanım yelpazesine sahip olan biyometrik sistemler, güvenlik tedbirlerinin en üst düzeyde uygulandığı alanlardan biri olan havaalanlarında da etkin bir şekilde kullanılmaktadır. Biyometrik tanıma sistemleri, kimlik doğrulamada fiziksel kart veya parola gibi ekipmanlara başvurmak yerine, kopyalanması ya da taklit edilmesi pratikte mümkün olmayan parmak izi, iris ve retina, yüz geometrisi, ses imzası, avuç içi damar haritası gibi kişiye özgü biyolojik karakteristikleri taramaya dayanır. Bu veriler devredilemez, unutulamaz ve kaybolamaz nitelikte olduğu için geleneksel kimlik denetim mekanizmalarına kıyasla daha yüksek güvenilirlik sağlamaktadır (Şamlı ve Yüksel, 2009).

1.1.3.6. Kapalı Devre TV Sistemleri (CCTV Sistemleri)

Kapalı devre tv altyapısı, havaalanı sahası ve çevresindeki tüm faaliyetlerin kesintisiz biçimde gözetlenmesine olanak tanımaktadır (TSA, 2004). Sabit ya da yönlendirilebilir kameralarca üretilen görüntü akışı, merkezi bir kontrol odasında eş-zamanlı izlenmekte ve analiz edilmektedir (Uzuner, 2003). Olumsuz ya da tehdit niteliği taşıyan bir durum tespit edildiğinde, ilgili güvenlik birimleriyle derhâl irtibat kurularak hızlı müdahale sağlanabilmektedir. Bu sistemde kullanılan kameralar, geleneksel güvenlik kameralarından farklı olarak; yüksek çözünürlükte görüntü sağlayabilen, termal (ısıya duyarlı) algılama yeteneğine sahip ve yapay zekâ destekli analiz kabiliyetine sahip akıllı kameralardır.

Bu sistemler, havacılık güvenliğine yönelik tehditlerin bertaraf edilmesinin yanı sıra olayların aydınlatılmasında da yüksek etkinlik göstermektedir. Bu sistem, sivil havacılık tesislerine yönelik olası saldırıları engellemek ve soruşturmakla kalmayıp, havaalanı sahasında meydana gelebilecek hırsızlık, kavga ve kap-kaç gibi diğer suçların önlenmesi ve çözüme kavuşturulmasında da önemli katkı sunmaktadır (Agustina ve Clavell, 2011).

1.1.4. Havaalanı Çevre Güvenliğinde Kameranın Rolü

Havaalanları geniş bir araziye yayılmış olup çevre güvenliği, havaalanı işletmesi ve uçuş emniyeti için kritik öneme sahiptir. Çevre güvenliğinde en yaygın ilk tedbir, tel örgü gibi fiziksel bariyerlerdir ancak standart bir çit ve dikenli tel, izinsiz bir kişi veya aracı yavaşlatabilse de güvenlik birimlerini otomatik olarak uyarmaz veya ihlali tamamen

engellemez (Barry, 2018). Nitekim son yıllarda çeşitli havaalanlarında çitleri aşarak pist alanına giren araç ve kişiler olmuş, ilk müdahale ekipleri yetişene dek uçaklara kadar yaklaşabilmişlerdir (Barry, 2018). Bu tür olaylar terör amaçlı olmasa bile mevcut çevre güvenlik sistemlerindeki zafiyeti gözler önüne sermiş ve havaalanı çevre güvenliğinin önemini pekiştirmiştir (Barry, 2018).

Günümüzde havaalanı işletmecileri, çevre güvenliğini sağlamak için gelişmiş teknolojilere yönelmektedir. Kamera tabanlı izleme sistemleri, geniş arazilerde 7/24 gözetleme imkânı sunarak hem güvenlik ihlallerini hem de yabancı hayvan girişlerini tespit etmede önemli bir bileşen haline gelmiştir.

Kamera sistemleri, havaalanı çevre güvenliğinde hem caydırıcı bir unsur hem de olay anında durum değerlendirmesi sağlayan kritik bir araçtır. Geleneksel olarak kapalı devre televizyon (CCTV) kameraları çevre sınırını izlemek ve bir ihlal durumunda operatörlerin olayı görsel olarak teyit etmesi için kullanılmıştır (Barry, 2018). Özellikle çevre ihlal tespit sistemlerinde (Perimeter Intrusion Detection Systems, PIDS) kameralar, tel örgü sensörleri veya radar gibi algılayıcılardan gelen alarmların doğrulanması için devreye girer (Barry, 2018). Birçok modern PIDS uygulamasında, algılama yapan farklı sensörler kamera görüntüleri ile entegre edilerek güvenlik personelinin durumu anında görmesine olanak tanınır (Barry, 2018).

Kameralar sadece pasif izleme aracı olmaktan çıkmış, gelişmiş video analitiği sayesinde aktif birer algılama sensörüne dönüşmüştür. Video analiz kabiliyeti olan akıllı kameralar, belirlenen sanal sınırların ihlalini veya şüpheli hareketleri otomatik olarak algılayabilir. Örneğin, kamera görüntüsü üzerinde tanımlanmış bir hat veya bölgeyi bir insanın geçmesi durumunda sistem otomatik alarm üretebilir. Bu sayede devriye personelinin fark edemeyebileceği uzak veya تنها bir noktadaki ihlal, anında tespit edilerek kontrol merkezine iletilir. Kameraların bu aktif rolü, geniş bir çevre hattına sahip havalimanlarında insan gözüyle sürekli izleme gereksinimini azaltmakta ve güvenlik ekibine ciddi bir avantaj sağlamaktadır (Plante, 2024).

Son olarak, kameraların konumlandırılması ve entegrasyonu da çevre güvenliğinde önemli bir husustur. Kör nokta bırakmayacak şekilde, görüş alanları örtüşecek biçimde kameraların yerleştirilmesi gerekir. Kritik noktalar (giriş kapıları, apron sınırları, ormanlık alan kenarları

vb.) ekstra kameralarla izlenmelidir. Tüm kameralar bir ađ üzerinden güvenlik kontrol merkezine bađlanır ve görüntüler kayıt altına alınır. Böylelikle hem gerçek zamanlı müdahale mümkün olur hem de olay sonrası inceleme için kanıt sađlanır. Özetle, kameraların dođru konfigürasyonu ve ileri analiz yetenekleri ile donatılması, havaalanı çevre güvenliğinde vazgeçilmez bir katman oluşturur.

Havaalanlarında uygulanan güvenlik protokolleriyle ilgili mevcut literatürde sınırlı sayıda çalışma bulunmaktadır. Bu araştırmada derin öğrenme tabanlı nesne tespit algoritmalarından biri olan You Only Look Once versiyon 10 (YOLOv10) yöntemi kullanılarak insan, hayvan ve nesne tespiti gerçekleştirilmiştir. Bu bağlamda, öncelikle literatür detaylı bir şekilde incelenmiş, güvenlik alanında kullanılan görüntü işleme ve nesne tespit teknikleri değerlendirilerek YOLOv10 algoritmasının havaalanı güvenliği kapsamında potansiyel kullanım alanları tartışılmıştır. Çalışma kapsamında elde edilen bulgular, mevcut yöntemlerle karşılaştırmalı olarak ele alınarak YOLOv10'nun avantajları, sınırlılıkları ve havaalanı güvenlik süreçlerine entegrasyonu açısından taşıdığı potansiyel değerlendirilmiştir.

2. İLİŞKİLİ ÇALIŞMALAR

Literatür taraması kapsamında, mevcut çalışmalar incelenmiş ve özellikle nesne tespiti, insan ve hayvan hareketliliğinin izlenmesi gibi konulara odaklanan araştırmalar değerlendirilmiştir. Bu bağlamda, görüntü algılamada yapay zekâ tabanlı yaklaşımların kullanımını ele alan çalışmalar analiz edilerek, YOLOv10 algoritmasının bu alandaki potansiyelini ortaya koyan örnekler incelenmiştir.

Sharma ve ark. (2014), hayvan (köpek) tanımlaması için normalleştirilmiş çapraz korelasyon yöntemini kullanmışlardır. Desen eşleştirme mekanizması yaklaşık 5000 görüntü üzerinde denenmiş, çeşitli köpek görüntüleri üzerinde yapılan çalışmada %86,25'lik tutarlılık elde edilmiştir (Sharma vd., 2014).

Eldem ve ark. (2017) ise kamera ile bireylerin fotoğraflarını kullanarak yüzlerini tanıma çalışması yapmışlardır. Açık kaynaklı bir veri tabanı olan OpenCV (Open Source Computer Vision Library) yardımı ile C# için geliştirilen OpenCVSharp kullanılmış, görüntülerin kayıtlarla karşılaştırılması sonucu ise yüz tanımda %79 doğruluk oranı elde edilmiştir (Eldem vd., 2017).

Yaban hayvanlarına yönelik görüntü analizi üzerine yapılan çalışmada, Yabanova ve Kaya (2019) farklı sınıflandırma yöntemlerinin performansları karşılaştırılmıştır. Bu çalışmada geliştirilen renksel öznitelik testi kullanılarak Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları tabanlı sınıflandırıcıların başarımları incelenmiş, Yapay Sinir Ağlarının DVM'ye kıyasla daha yüksek doğruluk oranına sahip olduğu belirlenmiştir. Elde edilen bulgular, önerilen yöntemin yabani hayvan türlerinin belirlenmesi ve sayımında %100 doğruluk oranına ulaştığını göstermektedir (Yabanova ve Kaya, 2019).

Algur ve ark. (2018) çalışmalarında dış ortam görüntülerindeki insanların hareketlerinin sınıflandırılmasına yönelik hibrit bir derin öğrenme modeli sunmuşlardır. Dış ortamlardan çekilmiş olan görüntülerdeki bireylerin tespitine yönelik olarak YOLO kullanılmıştır. Bunlar için Google Street View platformu tercih edilerek, Konvolüsyonel Sinir Ağı modeli yardımıyla sınıfları belirlenen nesnelerin tespit edilmeye çalışılmıştır. Dört sınıflı bir veri seti için sınıf doğrulama başarımları %85,71 olarak elde edilmiştir (Algur vd., 2018).

Başka bir çalışmada Şimşek ve ark. (2020), foto kapan görüntülerinden insan tespiti için

YOLO yöntemini kullanmışlardır. Bu çalışmada 2048*1536 boyutlarında toplam 2880 görüntü kullanılmıştır. Veri setinde 314 insan içeren görüntünün 297'si tespit edilerek %94,6 başarı oranı elde edilmiştir (Şimşek vd., 2020).

Derin öğrenme tabanlı YOLO algoritması, güvenlik alanında proaktif önlemlerin alınmasına ve hızlı aksiyon mekanizmalarının geliştirilmesine olanak sağlayarak güvenlik tedbirlerinin etkinliğini artırmaktadır. Bu bağlamda, gerçek zamanlı nesne tespiti ve tehdit analizi yapabilme kapasitesi sayesinde, güvenlik sistemlerinin daha dinamik ve öngörülebilir bir yapıya kavuşmasına katkı sağlamaktadır. Örneğin Choubisa ve ark. (2018), optik kamera tabanlı izinsiz giriş sınıflandırması çalışması yapmışlardır. Çalışmada, silahlı kişi ve araçlı kişi görüntüleri yanı sıra insan gezinmesi ve hayvan hareketi sınıflandırılmıştır. İnsan ve hayvan sınıfları arasında doğruluk oranları sırasıyla %95,65 ve %90'a yakın değerler elde edilmiştir. Ayrıca sınıflandırma için KSA tabanlı algoritma gerçek zamanlı olarak dış mekânda konuşlandırılmış ve %92 oranında sınıflandırma doğruluğu elde edilmiştir (Choubisa vd., 2018).

Önal ve Dandıl (2021) çalışmalarında, endüstriyel üretim alanında bireysel korumayı sağlayan donanımların kullanılmasının denetlenmesiyle güvenli olmayan hareketlerin tespiti için YOLOv4 kullanmışlardır. Çalışmada, çalışanların kullanmış olduğu baretlerin, yeleklerin, maskelerin, eldivenlerin ve gözlüklerin tanınmasına yönelik doğruluk değeri %91,18 olarak bulunmuştur (Önal ve Dandıl, 2021).

Çalışkan ve Demir (2022), şüpheli davranış tespiti üzerine yaptıkları çalışmada oluşturulan Marmara Üniversitesi Kriminal Davranış/Nesne (MÜKDN) veri setinde YOLOv4 ile tek sınıflı uygulamanın daha başarılı olduğu söylemiş ve yapılan çalışmada doğruluk değeri %86,66 olarak elde edilmiştir (Çalışkan ve Demir, 2022).

Nayak ve ark. (2019), gerçek zamanlı akıllı şehir uygulamalarında izinsiz giriş tespit sistemi üzerine çalışmışlardır. Çalışmada izinsiz girişlerin tespiti için YOLO, saldırganın gerçek zamanlı olarak takibi için ise Basit Çevrimiçi ve Gerçek Zamanlı Takip algoritması kullanılmışlardır. YOLOv2 ile yapılan eğitim sonucunda doğruluk değeri %97 olarak bulunmuştur (Nayak vd., 2019).

Ulaşım güvenliğine odaklanan bir başka çalışmada ise Sevi ve Aydın (2023), demiryolu hattı çevresindeki yabancı nesnelerin tespiti için 8500 yüksek çözünürlüklü RailSem19 veri seti kullanarak YOLOv8 tabanlı bir yaklaşım oluşturulmuştur. Eğitim prosesi için Google Colab kullanılmış ve değişik YOLOv8 alt tasarımları için ortalama hassasiyet mAP50 değerinde %88,8 doğruluk değeri elde edilmiştir (Sevi ve Aydın, 2023).

Son yıllarda derin öğrenme modelleri trafik alanında da sıklıkla kullanılmıştır. Alemdar (2024) çalışmasında, çift sıra parklanmanın nesne belirleme uygulaması üzerinde YOLOv8'le çalışmıştır. Model, Google Colab altyapısı kullanılarak eğitilmiştir. İzmit ile Erzurum'daki trafik yoğunluğu yüksek caddeler dikkate alınarak toplam 891 görüntü kullanılmış, ölçüm parametresi F1 skor değeri 0,83, modelin çift sıra parklanma, normal parklanma ve tüm veri setine ait mAP50 değerleri ise sırasıyla 0,851, 0,922 ve 0,886 olarak elde edilmiştir. Çift sıra parklanma tespitinde ise %89'luk bir doğruluk değeri bulunmuştur (Alemdar, 2024).

Sadık ve ark. (2024), araçların ve yayaların gerçek zamanlı tespiti ve analizi üzerine çalışmalar yapmışlardır. Zorlu kentsel ortamlar için YOLOv8I ve RT-DETR-L modellerinin kullanarak yaya sınıfı için sırası ile %82,2 ve %81,7'lik bir mAP doğruluk değeri elde etmişlerdir (Sadık vd., 2024).

3. PROBLEM TANIMI VE ÖN-BİLGİ

3.1. Problemin Durumu

Bu çalışma, YOLOv10 ile nesne (insan, kedi, ağaç, inek ve keçi) tespit sistemi ile havaalanı çevre sınırında oluşabilecek ihlallerin tespitinin yapılmasına odaklanılmaktadır. Havaalanı çevre güvenliğinde oluşabilecek ihlaller CCTV Sistemleri vasıtasıyla havaalanında yer alan güvenlik personeli tarafından kontrol edilmektedir. YOLOv10 ile belirtilen nesnelerin tespiti yapılacak ve belirlenecek hayali sınırı aşması durumunda ihlal, kontrol edici kısımda yer alan güvenlik çalışanının ekranına alarm olarak düşecektir. Bu minvalde, sınır ihlali olması durumunda tespit işlemi yapay öğrenme yöntemleriyle daha hızlı ve verimli bir şekilde gerçekleştirilebilecektir.

3.2. Araştırmanın Amacı

Bu tez çalışmasında amaç, ülkemizde bulunan ve stratejik öneme sahip havaalanlarının hem terminal hem pist hem de çevre güvenliğinin sağlanması için nesne (insan, kedi, ağaç, inek ve keçi) tespitinin derin öğrenme yaklaşımlarıyla yapılmasını sağlamaktır. Bu amaç doğrultusunda havaalanlarında oluşabilecek güvenlik açıklarının hızlı ve hassas bir şekilde tespit edilip ilgili birimlere iletilmesini sağlanacaktır. Bu çalışma, güvenlik personelinin kendi gözlemlerine göre daha verimli ve güvenilir bir tespit ve analiz etme süreci sağlamaktadır. Görüntü işleme ile çalışmada yer alacak veri setleri detaylı bir şekilde analiz edilip havaalanı çevresinde oluşabilecek ihlaller hakkında detaylı ve güvenilir bilgiler sunulabilecektir.

4. MATERYAL VE YÖNTEM

4.1. Veri Seti

Bu tez çalışması için kendi veri setimiz oluşturulmuştur. Çalışmada analizlerin yapılacağı videolar 2024 yılında sokakta gezinen insan ve kediden, bir duvar kenarında gezinen insanlardan, tel örgü yakınında ve insanla birlikte gezinen keçi ve ineklerden oluşmaktadır. Kalabalık sokakta gezinen insan videoları internet ortamında bulunmuş olup veri setine dahil edilmiştir. Veri setinde yer alan videolarda gezinen insan, kedi, inek ve keçi yer almaktadır. Ayrıca ağaçlar da veri setine dahil edilmiştir. Çünkü yerleşim yerlerine yakın havaalanlarında ağaç görüntüsü de kamera açısı içine girebilmekte ve rüzgar, gölge gibi etkenlerle yanlış alarmı sebep olabilmektedir. Her video için ayrı sınır hattı oluşturulmuş ve bu sınır hattının geçilmesi durumunda hem alarm üretilecek hem de sınır hattını geçen nesnenin sınıfı ve sayısı tespit edilebilecektir.


Tez çalışması iki uygulamadan oluşturulmuştur. Amaç, görüntü ve sınıf sayısındaki değişimleri göz önüne alarak çalışmanın başarı oranını ölçebilmektir. İlk uygulamada, yalnızca ağaç, insan ve kedi videoları dikkate alınmış, analizleri yapılmıştır. İkinci uygulamada ise görüntü sayısı ve sınıf sayısında değişikliğe gidilmiştir. Ağaç, insan, kedi, inek ve keçi görüntüleri dahil edilmiş olup bu görüntüler üzerinden analizler yapılmıştır. Sınıflandırma ve tespit işlemlerinin yapılabilmesi için YOLOv10 versiyonu kullanılmıştır.

Oluşturduğumuz veri setinde ilk uygulama için, şehir içi açık alanlar ve belli sınır yerlerinde insan ve hayvan (kedi) görüntüleri ile tespit ve sınıflandırma yapılmıştır. Görüntü içerisindeki insanların ve hayvanların tespit işlemi görüntü işleme alanında ele alınmıştır. Görüntüler, 30 frame per second (fps) ve 640*640 (genişlik*yükseklik) boyutunda 1000 adet renkli görüntüden oluşmaktadır. Bu verilerin %80'i eğitim, %20'si ise test için kullanılmıştır. Eğitimler, Google Colab altyapısı ile yapılmıştır. Çalışmanın ilk uygulamasında sınıfların eğitim ve test küme sayıları Çizelge 4.1'de gösterilmektedir.

Çizelge 4. 1. Çalışma için kullanılan Eğitim ve Test küme sayıları (1. Uygulama)

Analiz Sınıfı	Eğitim	Test
İnsan	450	110
Kedi	50	10
Ağaç	300	80
Toplam	800	200

Veri setinde yer alan görüntülerin etiketleme işlemi, nesne algılama, sınıflandırma ve segmentasyon için görüntü etiketlemede kullanılan Roboflow ile gerçekleştirilmiştir. Oluşturduğumuz veri setinin eğitimi ve testi için etiketleme işi Roboflow tarafından gerçekleştirilmiştir. Roboflow YOLO ile uyumlu etiketleme, nesne algılama, sınıflandırma ve segmentasyon için kullanılabilen bir yazılım aracıdır. Veri setindeki görüntüler Roboflow ile sınırlayıcı kutular (bounding box) tekniği ile etiketlenmiş ve insan, hayvan (kedi), nesne (ağaç) olarak 3 etiket sınıfı kullanılmıştır (Ultralytics, 2025). Çalışmada YOLOv10 modeli eğitim için kullanılmış olup aşamaları Şekil 4.1’de gösterilmektedir.



Şekil 4. 1. Çalışmanın iş akış diyagramı

Çalışmada Python programlama dili ve IDE (Integrated Development Environment – Entegre Geliştirme Ortamı) olarak ise PyCharm kullanılmıştır. Sınıflandırma ve tespit yapabilmek için yazılan kodlar Şekil 4.2’de gösterilmektedir.

Pusedo Code

Başla

1. YOLOv10 modelini yükle

```
model = YOLOv10('best.pt')
confidence_threshold = 0.5 # Güven eşiği
```

2. Video dosyasını aç

```
video_path = "video8.mp4"
video_input =
open_video(video_path)
```

3. Çıktı video dosyasını oluştur

```
video_output = create_video_writer('8.mp4', video_input.width, video_input.height)
```

4. Video üzerinde her bir frame'i işle

```
while video_input.has_frames():
    frame =
    video_input.read_frame()
```

5. Çerçeve boyutlarını al

```
height, width = frame.shape
```

6. Çizgi için yatay koordinat hesapla

```
line_x = int(width * 0.7) # Çizgi %70 sağa kaymış
```

7. Model ile nesne tespiti yap

```
detections = model.detect(frame)
```

8. Düşük güvenli tespitleri filtrele

```
valid_detections = filter_detections(detections, confidence_threshold)
```

9. İhlal sayısını başlat

```
violation_count = initialize_violation_count()
```

10. Nesnelerin sınırı aşma durumunu kontrol et

```
for each_detection in valid_detections:
    if object_crosses_boundary(each_detection, line_x):
        increment_violation_count(violation_count, each_detection)
```

```

# 11. Çizgi rengini belirle
if sum(violation_count.values()) > 0:
    line_color = "RED"
    display_message(frame, "SINIR ASILDI!",
line_x) else:
    line_color = "GREEN"
# 12. Çerçeveye sınır çizgisini çiz
draw_boundary_line(frame, line_x, line_color)
# 13. İhlal bilgilerini ekrana yazdır
display_violation_info(frame, violation_count)
# 14. Çerçeveye etiketler ekle
annotated_frame = annotate_frame(frame, valid_detections)
# 15. Çerçeveyi video dosyasına yaz
video_output.write(annotated_frame)
# 16. Çerçeveyi ekranda göster
show_video_frame(annotated_frame)
# 17. Video işleme tamamlandıktan sonra dosyaları serbest bırak
release_video_resources(video_input, video_output)
Bitir

```

Şekil 4. 2. Çalışmada kullanılan Pusedo Code

Tez çalışmasının ikinci uygulamasında ise insan, nesne (ağaç), hayvan (kedi, inek, keçi) tespiti yapabilmek için görüntüler üzerinde analizler yapılmıştır. Sınıflandırma ve tespit işlemlerinin yapılabilmesi için YOLOv10 versiyonu kullanılmıştır.

Oluşturduğumuz veri setinde ikinci uygulama için, şehir içi açık alanlar ve belli sınır yerlerinde insan ve hayvan (kedi) görüntüleri ile tespit ve sınıflandırma yapılmasının yanında otlak arazide gezinen inek ve keçi görüntülerinden de yararlanılmış ve bu sınıflar için de tespit ve sınıflandırma yapılmıştır. Görüntü içerisindeki yeni sınıf türünden olan inek ve keçinin tespit işlemi görüntü işleme alanında ele alınmıştır. Görüntüler, 30 frame per second (fps) ve 640*640 (genişlik*yükseklik) boyutunda 875 adet renkli görüntüden

oluşmaktadır. Veri kümesi toplam 875 adet renkli görüntüden oluşmaktadır. Bu görüntüler, modelin eğitim, doğrulama ve test aşamalarında kullanılmak üzere üç alt gruba ayrılmıştır. Modelin eğitimi için verinin büyük çoğunluğu ayrılmış, kalan kısmı ise doğrulama ve test işlemleri için kullanılmıştır. Eğitimler, Google Colab altyapısı ile yapılmıştır. Çalışmanın ikinci uygulamasında sınıfların eğitim, doğrulama ve test küme sayıları Çizelge 4.2’de gösterilmektedir.

Çizelge 4. 2. Çalışma için kullanılan Eğitim ve Test küme sayıları (2. Uygulama)

Analiz Sınıfı	Eğitim	Doğrulama	Test
İnsan	180	20	10
İnek	150	13	7
Kedi	150	13	7
Ağaç	155	16	8
Keçi	130	11	5
Toplam	765	73	37

Veri setinde yer alan görüntülerin etiketleme işlemi, Roboflow ile gerçekleştirilmiştir. Veri setindeki görüntüler Roboflow ile sınırlayıcı kutular (bounding box) tekniği ile etiketlenmiş ve insan, hayvan (kedi, inek, keçi), nesne (ağaç) olmak üzere 5 etiket sınıfı kullanılmıştır.

4.2. Derin Öğrenme

Kullanıcının açıkça talimat veya komut vermesine gerek kalmadan bilgisayar sistemlerinin önceden belirlenmiş belirli bir görevi yerine getirmesine olanak tanıyan istatistiksel modellerin bilimsel olarak incelenmesi, makine öğrenimi (*machine learning – ML*) olarak bilinir (Bingöl vd., 2020). Makine öğrenimi, yapay zekâ araştırmalarının bir alt dalını oluşturur. Makine öğrenimi, görüntü ve görüntü tanıma uygulamalarında yaygın olarak kullanılmaktadır. Bilgisayarın söz konusu görüntüyü öğrenebilmesi için görüntü tanıma uygulamalarında sayısal tabanlı görüntülerin devreye girmesi gerekmektedir. Böylelikle sistem görseller arasındaki farkları hızlı bir şekilde tespit edebilir ve benzer görsellerin ortak özelliklerini tanımlayabilir olmaktadır (Akmeşe vd., 2023).

Derin öğrenme (*deep learning – DL*) öğrenme sürecini yönetmek için yapay sinir ağlarının

hiyerarşik seviyelerini kullanan bir yapay zekâ yaklaşımıdır. Makine öğrenimi metotları içerisinde yer alan derin öğrenme, yapılandırılmamış (*unstructured*) veya etiketlenmemiş (*unlabeled*) verilerden denetimsiz öğrenebilen (*unsupervised*) ağlara sahip makine öğrenme mimarilerini kullanır (Bengio, 2009). Resim 4.2’de, Yapay zekâ kavramının derin öğrenme kavramına kadar gelişim evreleri yıllara göre detaylı gösterilmiştir.



Resim 4. 2. Yapay zekânın gelişim süreci (Copeland, 2020).

Derin öğrenme, geniş veri setlerini işleme kapasitesi ve karmaşık desenleri öğrenme yeteneği sayesinde çeşitli disiplinlerde uygulanabilen bir teknolojidir. Sürekli olarak gelişen bu alan, yeni kullanım alanlarının keşfiyle birlikte hızla ilerlemekte ve inovatif çözümler sunmaktadır.

Derin öğrenme; nesne tespiti, ses işleme-tanıma, görüntü işleme-sınıflandırma, yüz tanıma, doğal dil işleme, hava durumu tahmini, finansal veri tahmini gibi birçok alanda yaygın olarak kullanılmaktadır. Bilim ve teknolojinin birçok alanında önemli ilerlemelere yol açmıştır (Chollet, 2020).

Derin öğrenme, temel olarak veri temsili üzerinden öğrenme ilkesine dayanmaktadır. Özellikle görüntü analizine odaklandığımızda, temsil kavramı piksel yoğunluklarından oluşan vektörlerden, kenar kümelerine veya özel şekil özelliklerine kadar geniş bir yelpazede düşünülebilir. Bu özellikler arasında, veriyi en etkili şekilde temsil edenleri seçmek önemlidir (Şeker vd., 2017).

Derin öğrenme, havaalanı çevre güvenliği alanlarında ise sınır hattı güvenliği, izinsiz giriş

tespiti, güvenlik kameraları aracılığıyla tehdit analizi, otomatik tarama sistemleri, sınır güvenlik personelinin desteklenmesi ve tehlikeli durumların erken tespiti gibi uygulamalarda kullanılmaktadır. Bu uygulamalar, derin öğrenmenin havaalanı güvenliği sektöründeki potansiyelini göstermektedir. Bu teknolojiler, güvenliği artırmak, kaynakları daha etkin kullanmak ve sürdürülebilir güvenlik önlemlerini desteklemek amacıyla geliştirilmektedir. Bu uygulamaların geliştirilmesinde temel kaynak, güvenlik uzmanlarının kararlarına dayanmaktadır. Son yıllarda geleneksel güvenlik analiz yöntemlerinin yerini derin öğrenme teknikleri almıştır, özellikle evrişimli sinir ağı modelleri, havaalanı güvenliği alanında yüksek doğruluk oranları ile kullanılmaktadır.

4.3. Evrişimli Sinir Ağları (CNN: Convolutional Neural Network)


Çeşitli derin öğrenme yöntemleri, farklı nesne sınıflarının sınıflandırılması gibi çeşitli makine öğrenimi görevlerini yapmak için sinir ağı algoritmalarını eğitmek için verileri kullanır. CNN ağıdaki katmanlardan bazılarının etkili bir şekilde eğitildiği, görüntü analizi için önemli derin öğrenme tekniklerinden biridir (Ayyüce Kızrak ve Bolat, 2018; Oh vd., 2021).

CNN derin öğrenme alanının en önemli alt dallarından biri olup, özellikle dijital görüntü işleme ve bilgisayarla görme (computer vision) uygulamalarında yaygın olarak kullanılmaktadır. CNN'ler, biyolojik sinir ağlarından esinlenerek geliştirilmiş yapay sinir ağı (ANN) modelleridir ve temel olarak görüntüleri analiz etmek için tasarlanmıştır. CNN'lerin özelliği, görüntülerdeki farklı özellikleri tanıma ve öğrenme yeteneği sunan evrişim (convolution) işlemi kullanmalarıdır. Bu ağlar, özellikle veri üzerinde manuel özellik çıkarımı yapılmasına gerek kalmadan, verinin yapısını ve özelliklerini kendiliğinden öğrenebilme kapasitesine sahiptir.

CNN, dijital görüntü işleme alanında son yıllarda en güçlü algoritmalar arasında yer almaktadır. Bu algoritmalar, özellikle görüntüler üzerinde yapılan otomatik işleme işlemlerinde yüksek verimlilik ve doğruluk sağlamaktadır. CNN'ler, genellikle görüntülerdeki özellikleri çıkarmak ve nesneleri tanımak gibi karmaşık görevleri başarıyla yerine getirmektedir. Bu nedenle, nesne tanıma, görüntü sınıflandırma ve segmentasyon gibi uygulamalarda yaygın olarak kullanılmaktadır. Dijital görüntülerin analizinde, CNN'ler, görüntüdeki yapısal ve uzamsal ilişkileri etkili bir şekilde öğrenme kapasitesine sahip olması

nedeniyle, geleneksel yöntemlere kıyasla önemli avantajlar sunmaktadır.

CNN derin öğrenmenin en iyi modellerinden biridir. CNN, ANN gibi girdi, çıktı ve birkaç gizli katmandan oluşan çok katmanlı bir yapıya sahiptir. Bir evrişimli sinir ağının üç ana katmanı vardır: bir evrişim katmanı, bir havuzlama katmanı ve bir tam bağlantılı katman bulunmaktadır. İlk iki katmanda girdi olarak alınan görüntüden özellikler çıkarılır ve bu çıktılar çıkış katmanına eşleştirilir (Daşkın vd., 2018). Şekil 4.3'te, Evrişimli Sinir ağlarının mimari yapısı gösterilmektedir.



Şekil 4. 3. Evrişimli Sinir Ağı Mimarisi (CNN)

Farklı veri kümeleri üzerinde uygulanan önceden eğitilmiş CNN modelleri, sınıflandırma başarısını önemli ölçüde artırma potansiyeline sahiptir. Bu yaklaşım, CNN mimarilerinin veri kümelerine adapte edilmesiyle, modelin performansını daha verimli hale getirmeyi amaçlamaktadır. Aşağıda, kullanılan bazı ön-eğitilmiş CNN mimarilerine dair bilgiler sunulmaktadır.

4.3.1. Giriş katmanı (Input layer)

4.3.2. Evrişim katmanı (Convolution layer)

Evrişimli Sinir Ağı modelinin temel yapı taşlarından biri olan bu katman, literatürde sıklıkla “dönüşüm katmanı” olarak adlandırılmaktadır. Bu katmanda gerçekleştirilen işlem, belirli bir filtrenin giriş görüntüsü üzerinde kaydırılması prensibine dayanmaktadır. Bu nedenle, filtreler evrişim tabanlı mimarinin vazgeçilmez unsurlarını oluşturmaktadır. Filtreler, önceki katmandan aktarılan giriş verilerine evrişim (convolution) operatörünü uygulayarak, sonraki aşamada kullanılacak özellik haritalarını üretir. Bu işlem sonucunda ortaya çıkan aktivasyon haritaları (feature maps), her bir filtrenin algıladığı özgül özelliklerin uzamsal olarak temsil edildiği bölgelerdir. Modelin eğitim süreci boyunca bu filtrelerin ağırlıkları, eğitim verisi üzerinde yapılan her öğrenme döngüsünde güncellenerek optimize edilir. Bu sayede ağ, hangi uzamsal bölgelerin anlamlı olduğunu öğrenir ve bu bölgeleri öne çıkararak sınıflandırma ya da tespit gibi görevlerde daha başarılı sonuçlar üretir.

Bu katmandan gelen görüntü bir filtreden geçer. Öznitelik matrisi, filtreleme yoluyla elde edilen değerlerle oluşturulur. Elde edilen çıktı matrisi, evrişim çekirdeğinin tüm giriş tensörü üzerinde sistematik olarak kaydırılmasıyla oluşturulur. Girdi, renkli bir görüntü olduğunda ise her bir spektral kanal (örneğin Kırmızı, Yeşil, Mavi) bu işlemi bağımsız biçimde yürüterek kendisine özgü özellik haritalarını üretir. (Karaoğlu, 2022).

4.3.3. Aktivasyon katmanı (Activation layer)

Aktivasyon işlevlerinin yürütüldüğü katmandır. Aktivasyon fonksiyonu, bilgisayar biliminde kullanılan yapay sinir ağlarının temel bir bileşeni olarak, insan beynindeki nöronların işlevine benzer bir şekilde çalışır. Bu fonksiyonlar, bir nöronun bir sonraki nörona hangi bilgileri ileteceğini belirlemede kilit bir rol oynar. Doğrusal olmayan (non-linear) aktivasyon fonksiyonları, modele lineer olmayan özellikler kazandırarak daha karmaşık veri yapılarını öğrenme kapasitesini artırır ve böylece modelin genel doğruluğunu optimize eder (Naes, 2023). Bir nöron tüm girdi değerlerini topladıktan sonra aktivasyon fonksiyonuna gönderilir. Bir sonraki katmana aktarılacak çıktı miktarı, aktivasyon fonksiyonu tarafından belirlenir. Çıktı değerleri genellikle $0 - 1$ ya da $(-1) - 1$ aralığında sınırlandırılır. Aktivasyon katmanında çoğunlukla Doğrultulmuş Doğrusal Birim (ReLU) tercih edilir. ReLU, ileri besleme ve geri yayılım süreçlerinde yaygın diğer fonksiyonlara göre daha düşük hesaplama yüküyle daha hızlı tepki üretir (Karasu, 2019).

4.3.4. Havuzlama katmanı (Pooling layer)

Alt örnekleme katmanı, giriş özelliği haritalarının boyutunu küçülterek parametre sayısını ve hesaplama maliyetini düşürür. Bu katmanda kullanılan pencere, evrişim katmanında olduğu gibi tüm giriş tensörü üzerinde kaydırılsa da öğrenilebilir ağırlıklar içermediği için evrişimsel işlemlerden ayırır ve yalnızca istatistiksel bir özet (örneğin maksimum veya ortalama değer) üretir (Gong vd., 2014). Maksimum ve ortalama havuzlama en yaygın iki türdür. Ortalama havuzlama, pencereyi özellik haritasının üzerine kaydırıp ortalama değerini alırken, maksimum havuzlama, pencerenin maksimum değerini alır. Evrişimsel ve havuzlama katmanları, derin ağırlık hiyerarşik temsil öğrenme sürecinde birbirini tamamlayarak etkin özellik çıkarımı işlevini üstlenir (Benli, 2021).

4.3.5. Tam bağlı katman (Fully connected layer)

Tam bağlantılı katman, önceki evrişim ve havuzlama katmanlarında çeşitli filtreler aracılığıyla çıkarılan öznitelikleri bütüncül bir vektörel temsile dönüştürerek son sınıflandırma işlemini üstlenir. Evrişimsel ve havuzlama aşamaları çoğunlukla ReLU aktivasyonundan yararlanırken, tam bağlantı katmanı genellikle softmax işlevini kullanarak her sınıf için 0 ile 1 arasında olasılık değerleri üretir ve böylece modelin nihai kararını biçimlendirir. (Lin vd., 2015).

Son evrişim ya da havuzlama katmanının ürettiği özellik haritaları önce düzleştirme işlemine tabi tutularak çok boyutlu tensörlerden tek boyutlu bir vektöre indirgenir. Bu vektör daha sonra, her giriş nöronunun her çıkış nöronuna öğrenilebilir ağırlıklarla eksiksiz biçimde bağlandığı bir veya birden fazla tam bağlantılı (yoğun) katmana aktarılır. (Prajapati vd., 2019). Evrişimsel ve havuzlama katmanlarının alt örnekleme yoluyla ürettiği yapısal temsiller, ağırlık çıktısı alanına her hedef sınıfa karşılık gelen olasılık değerlerini hesaplayacak biçimde tam bağlantılı katmanın belirli nöron alt kümeleri tarafından yansıtılır. Söz konusu tam bağlantılı katman genellikle, problemde tanımlı sınıf sayısı ile bire bir özdeş düğüm sayısına sahip olacak şekilde yapılandırılır. (Cimpoi vd., 2016).

4.3.6. Sadeleştirme katmanı (Dropout layer)

Yapay Sinir Ağlarında veriler eğitilirken benzer verilerin çok fazla kullanılması aşırı öğrenmeye neden olur ve sinir ağları ezberler, ezber yapan sinir ağı da sonuç üretirken uydurur. Aşırı uydurmayı önlemek için sinir seyreltme (dropout) işlemi uygulanır. Parametre ölçeği bakımından zengin derin sinir ağları, makine öğrenmesi alanında en yüksek temsil kapasitesine sahip ileri düzey modelleri oluşturmaktadır. Bu tür ağlarda aşırı uyum ciddi bir sorundur. Ayrıca, yüksek parametreliliğin çalıştırılması görece yavaş olduğundan, test aşamasında birden fazla büyük sinir ağının çıktısını birleştirerek aşırı uyum sorununu azaltmak güçleşmektedir. Aşırı uyum sorununu hafifletmenin yaygın yollarından biri seyreltme (dropout) düzenlemesidir. Dropout tekniği, görüntü tanıma, konuşma tanıma, doküman sınıflandırması gibi çeşitli denetimli öğrenme sinir ağlarının performansını artırdığını göstermiştir. Seyreltme işlemi ile bir sinir düğümü yok sayılarak yok sayılan düğümün tüm bağlantıları kesilir yani o düğümün önceki ve sonraki katmanlarla olan bilgi akışı engellenir. Bu teknik nesne sınıflandırma, basamak tanıma, konuşma tanıma, belge sınıflandırması ve hesaplamalı biyoloji verilerinin analizi dahil olmak üzere çok çeşitli uygulama alanlarında ANN'nin performansını iyileştirdiği tespit edilmiştir (Bozkurt, 2021).

4.4. YOLO (You Only Look Once)

YOLO (You Only Look Once) modeli, yüksek doğruluk oranı ve gerçek zamanlı işlem kabiliyeti ile nesne tespitinde öne çıkan yöntemlerden biridir. Basit bir evrişimli sinir ağı (CNN) yapısı üzerine kurulu olan bu tek aşamalı derin öğrenme mimarisi, sınıf olasılıklarını ve sınır kutularını doğrudan giriş görüntüsü üzerinden tahmin etmektedir.

YOLO (You Only Look Once), nesne algılama ve tanıma görevlerinde yaygın olarak kullanılan, derin öğrenme temelli bir algoritmadır. Algoritma, görüntü üzerindeki nesneleri tek bir aşamada tespit edip sınıflandırması sayesinde hem yüksek doğruluk hem de düşük gecikme süreleriyle dikkat çeker. Bu yönüyle, özellikle gerçek zamanlı uygulamalar için oldukça elverişli bir çözüm sunmaktadır.


YOLO algoritması, geleneksel çok aşamalı nesne algılama yöntemlerinin aksine, bir görüntüyü doğrudan bir evrişimli sinir ağına (CNN) aktararak çıktıda nesne sınıflarını ve bunlara karşılık gelen sınırlayıcı kutuları eş zamanlı olarak üretmektedir. Bu yapı hem

hesaplama verimliliği sağlar hem de sistemin uçtan uca eğitilmesine olanak tanır. Böylelikle YOLO, nesne algılama, görüntü sınıflandırma ve hatta bazı durumlarda görüntü segmentasyonu gibi görevleri tek bir ağ yapısı içerisinde gerçekleştirebilmektedir.

YOLO mimarileri, çeşitli sektörlerde farklı amaçlarla etkin biçimde kullanılmaktadır. Örneğin, güvenlik sistemlerinde, insan, hayvan veya şüpheli nesne tespiti için kullanılarak gözetim sistemlerinin otomasyonu sağlanmaktadır. Sağlık sektöründe, tıbbi görüntülerde anomali tespiti (örneğin tümör bölgeleme) gibi uygulamalarda yüksek başarı oranları sergilemektedir. Tarım teknolojilerinde, ürün tanıma, hastalık tespiti ve zararlı analizlerinde kullanılarak tarımsal verimliliğin artırılmasına katkı sağlamaktadır. Otomotiv sektöründe, özellikle otonom sürüş sistemlerinde yol üzerindeki nesnelerin (araç, yaya, trafik levhası vb.) tespiti amacıyla sisteme entegre edilmektedir.

Bu yönleriyle YOLO algoritması, derin öğrenmenin bilgisayarlı görü alanındaki en güçlü uygulamalarından biri olarak konumlanmaktadır. Uygulama çeşitliliği ve gerçek zamanlı çalışabilme yeteneği sayesinde hem akademik araştırmalarda hem de endüstriyel sistemlerde tercih edilmektedir.

YOLO algoritması, çağdaş nesne algılama yaklaşımlarının çoğunda olduğu gibi temelde evrimsel sinir ağlarından yararlanır; ancak iki aşamalı bölge-önerili çerçevelerin aksine, giriş görüntüsünü tek bir ileri geçişle bütüncül biçimde işleyerek nesne sınıflandırma ile konum kestirimini eşzamanlı biçimde gerçekleştirir. Bu “tek atımlı” tasarım, Faster R-CNN ve SSD gibi popüler mimarilere kıyasla ortalama doğruluk metriklerinde daha yüksek başarı gösterirken, gerçek zamanlı uygulamalarda gereken düşük gecikme sürelerini de koruyabilmektedir. Bundan dolayı diğer nesne tespit yöntemlerinden daha kullanışlı olup tercih edilmesine neden olmaktadır. Resim 4.3'te YOLO'nun genel çalışma prensibi yer almaktadır.



Resim 4. 3. YOLO'nun genel çalışma prensibi (Redmon vd., 2016)

Resim 4.3'te görüldüğü üzere, YOLO algoritmasının temelinde, giriş görüntüsünün $S \times S$ boyutlarında bir ızgara yapısına bölünmesi prensibi yer almaktadır (genellikle $S=7$ olarak alınır). Bu bölütleme işlemi sonucunda elde edilen her bir ızgara hücresi, kendi sınırları içerisinde yer alan bir nesneye ait belirli bilgileri öğrenmek ve tahmin etmek üzere yapılandırılmaktadır.

Her bir hücre, öncelikle sahne içerisinde bir nesnenin merkez koordinasyonunun kendi sınırları içerisinde bulunup bulunmadığını değerlendirir. Eğer bir nesnenin merkezi ilgili hücreye düşüyorsa, bu hücre aşağıdaki bilgileri içeren bir tahmin vektörü üretir: Nesnenin yatay konumunu (x koordinatı), dikey konumunu (y koordinatı), sınırlayıcı kutunun yüksekliği ve genişliğini (h, w), ilgili nesneye ait güven oyunu (confidence score) ve tahmin edilen nesnenin, önceden tanımlı sınıflardan hangisine ait olduğuna dair sınıf benzerlik oranını göstermektedir.

Bu bağlamda güven oyu, ilgili hücrede gerçekten bir nesne olup olmadığını ifade eder ve yalnızca nesne bulunduğu durumlarda hesaplanan Intersection over Union (IoU) değeriyle ilişkilendirilerek modelin doğruluğunu artırır. IoU, tespit edilen sınırlayıcı kutu ile eğitim

verisindeki etiketli nesnenin kutusu arasındaki örtüşme oranını temsil eder.

Sonuç olarak, her hücre yalnızca merkezi kendisine ait olan nesnelerden sorumlu olacak şekilde konumlandırma (x, y), boyutlandırma (w, h) ve sınıflandırma (class probability) görevlerini aynı anda yerine getirir. Bu yapı sayesinde, bir nesnenin görüntüdeki konumu ve ait olduğu sınıf, doğrudan modelin çıktısından elde edilebilmektedir. Bu yaklaşım hem konumsal hem de anlamsal bilgi çıkarımı açısından YOLO algoritmasının gerçek zamanlı nesne algılama görevlerinde yüksek verimlilikle çalışmasını mümkün kılmaktadır.

4.5. YOLOv10 Sürümü

YOLOv10, son yıllarda tanıtılmış olan, gerçek zamanlı ve uçtan uca çalışan bir nesne tespit algoritmasıdır. YOLO serisinin temel özelliklerini temel alırken, çeşitli yönleri iyileştirerek ve yenilikler katarak tespit performansını ve verimliliği daha da artırmayı hedeflemektedir. YOLOv10'daki başlıca ilerlemeler, son işlem (post-processing) stratejileri ve model mimarisi tasarımı etrafında şekillenmiştir. Bu geliştirmelerin temel amacı; hesaplama yükünü azaltmak, çıkarım (inference) hızını artırmak ve yüksek doğrulukta tespit sağlamaktır (Wang vd., 2024).

Klasik nesne tespit algoritmaları arasında yer alan Mask R-CNN, RetinaNet, SSD, EfficientDet, CenterNet ve YOLO, farklı uygulamalar için kendine özgü güçlü yönler sunar:

- **Mask R-CNN**, segmentasyon kalitesi açısından oldukça başarılıdır ancak yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalarda tercih edilmesi zordur (He vd., 2018).
- **RetinaNet**, özellikle küçük nesnelerin tespitinde Focal Loss ile doğruluğu artırır fakat bu da hesaplama ve bellek yükünü yükseltir (Lin vd., 2017).
- **SSD**, tek aşamalı (single-shot) tasarımı sayesinde gerçek zamanlı tespit için uygundur ancak küçük nesneleri ve yüksek çözünürlüklü görüntüleri tespit etmekte zayıf kalabilir (Liu vd., 2016).
- **EfficientDet**, hesaplama verimliliğini optimize eder ve bellek kullanımını azaltır

Şekil 4.4'te görüldüğü üzere, YOLOv10 ağ mimarisi dört ana bileşenden oluşur: Girdi (Input), Omurga (Backbone), Boyun (Neck) ve Baş (Head).

Input (Girdi) Modülü: Eğitim veri kümesinin çeşitliliğini artırmak ve aşırı öğrenmeyi (overfitting) azaltmak amacıyla Mosaic ve Copy-Paste gibi veri artırma (data augmentation) yöntemleri kullanılmıştır (Bochkovskiy vd., 2020; Ghiasi vd., 2021). Bu yöntemler, modelin yeni durumlara güncelleme yapma yeteneğini artırır. Özellikle, karmaşık arka planlara karşı dayanaklılığı artırmak ve gürültü etkisini azaltmak için bu teknikler dikkatlice ayarlanmıştır. Bu artırımların şiddeti, veri çeşitliliği ile gürültü bastırma arasında denge kuracak şekilde dinamik olarak ayarlanmıştır. Ayrıca, eğitim sürecinin son 10 aşamasında bu teknikler devre dışı bırakılarak modelin kararlılığı sağlanmıştır (Liao vd., 2025).

Backbone (Omurga) Modülü: Omurga Modülü, öznitelik çıkarımı için kritik öneme sahiptir ve şu bileşenleri içerir:

- **SCDown (Spatial Channel Decoupling Downsampling):** Verimli öznitelik indirgeme için uzamsal ve kanal ayrıştırma, farklı ölçeklerde öznitelik çıkarımını geliştirerek uzamsal kanal verilerini optimize eder.
- **C2f bileşeni:** Bilgi akışını artırırken parametre verimliliğini koruyan, kısmi bağlantı ve çoklu konvolüsyon bloklarıyla yapılandırılmış hafif bir özellik çıkarım modülüdür.
- **SPPF (Spatial Pyramid Pooling-Fast):** Daha güçlü öznitelik temsili sağlar. Alıcı alanını (receptive field) genişleterek büyük hedeflerin tespitini destekler.
- **PSA (Partial Self-Attention):** Önemli bilgileri vurgulayarak öznitelik haritalarını iyileştirir. Küçük hedeflerin daha iyi tespit edilmesini sağlar (Liao vd., 2025).

Neck (Boyun) Modülü: YOLOv10, boyun kısmında PAFPN (Path Aggregation Feature Pyramid Network) kullanır (Liu vd., 2018). Bu yapı, FPN (Feature Pyramid Network) ve PANet'in avantajlarını birleştirerek çok ölçekli öznitelik birleştirmeyi verimli şekilde sağlar. Böylece, farklı boyutlardaki hedeflerin daha doğru tespiti mümkün olur (Liao vd., 2025).

Head (Baş) Modülü: YOLOv10, ayrıştırılmış bir baş (decoupled head) yapısı kullanır. Burada, YOLOv8'in C2f modülünün geliştirilmiş bir versiyonu olan C2fCIB modülü yer

alır (Varghese ve Sambath, 2024). C2fCIB, çok seviyeli öznitelikleri bir araya getirerek küçük nesne tespiti geliştirir, aynı zamanda alıcı alanı ve öznitelik temsil gücünü artırır. YOLOv10 ayrıca, sınıflandırma başlığını hafifletmiş ve önceki sürümlerdeki “hedef branşı”nı kaldırarak, bağımsız sınıflandırma ve regresyon dallarına odaklanmıştır (Liao vd., 2025).

4.6. Performans Metrikleri

Bir modelin performansını değerlendirmek yapılan çalışmanın en önemli kısımlarından biridir. Model performansını ölçmek için kullanılan çeşitli başarımlı ölçütleri bulunmaktadır. Geliştirilen bir modelin etkinliğini değerlendirmek, bir araştırmanın temel aşamalarından biridir. Modelin performansını objektif bir biçimde ölçmek için çeşitli başarımlı metrikleri kullanılmaktadır. Bu metrikler, modelin genel başarı düzeyini nicel olarak değerlendirmeye ve karşılaştırmaya imkân sağlar (Ünal, 2024).

4.6.1. Karışıklık matrisi

Karışıklık matrisi (confusion matrix), sınıflandırma problemlerinde bir modelin başarısını değerlendirmek için kullanılan önemli bir araçtır. Bu matris, modelin gerçekleştirdiği sınıflandırma tahminlerini ve gerçek sınıfları karşılaştırarak farklı performans metriklerini hesaplamak için kullanılır (Aktaş, 2020).

Karışıklık matrisi, sınıflandırma problemlerinde modelin tahmin performansını görselleştirmek amacıyla kullanılan temel araçlardan biridir. Bu matrisin satır kısmı gerçek sınıf etiketlerini, sütun kısmı ise model tarafından tahmin edilen sınıfları göstermektedir. Böylelikle her bir sınıf için, gerçekte hangi sınıfa ait olduğu ve modelin bu durumu nasıl tahmin ettiği açıkça izlenebilmektedir. Çalışma kapsamında Çizelge 4.3'te, ikili sınıflandırmaya yönelik olarak hazırlanmış bir karışıklık matrisi gösterilmiş ve modelin performansı gösterilen çizelgeye göre değerlendirilmektedir. Karışıklık matrisi, modelin öngördüğü etiketlerle gerçek sınıf etiketlerinin kesişiminde oluşan dört temel hücre değerini içermektedir (Yıldırım vd., 2023). Bunlardan;

Doğru Pozitif (True Positive) değeri, gerçek sınıfın pozitif olduğu ve modelin de pozitif öngöründe bulunduğu durumlar.

Yanlış Pozitif (False Positive) değeri, gerçek sınıfın negatif olmasına karşın modelin de pozitif öngöründe bulunduğu durumlar.

Doğru Negatif (True Negative) değeri, gerçek sınıfın negatif olduğu ve modelin de negatif öngöründe bulunduğu durumlar.

Yanlış Negatif (False Negative) değeri ise, gerçek sınıfın pozitif olmasına karşın modelin de negatif öngöründe bulunduğu durumlardır.

Doğru Pozitif (DP) ve Doğru Negatif (DN) modelin doğru tahminlerini, Yanlış Pozitif (YP) ve Yanlış Negatif (YN) ise modelin yanlış tahminlerini gösterir (Yıldırım vd., 2023).

Analizde kullanılan sınıflandırma modellerinin elde ettiği sonuçların daha anlaşılır ve yorumlanabilir hâle getirilmesi amacıyla, tahmin edilen değerlerin doğruluğu ve hata oranları çapraz biçimde incelenmiştir. Bu değerlendirme sürecinde karışıklık matrisi temel araç olarak kullanılmıştır. Söz konusu karışıklık matrisi, modelin doğru ve yanlış sınıflandırmalarını sistematik biçimde ortaya koymakta, böylece model performansına ilişkin kapsamlı bir bakış açısı sunmaktadır. Çizelge 4.3'te, ikili sınıflandırma problemi için oluşturulmuş karışıklık matrisine dayalı sistem gösterilmektedir.

Çizelge 4. 3. İkili sınıflandırma için karışıklık matrisi

KARIŞIKLIK MATRİSİ		TAHMİN DEĞERLERİ	
		Pozitif	Negatif
GERÇEK DEĞER	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk (Accuracy)

Tüm sınıfları kapsayan küresel bir performans göstergesidir; modelin doğru sınıflandırdığı örnek sayısının toplam örnek sayısına oranlanmasıyla hesaplanır. 0 ile 1 arasında değer almaktadır (Ciran ve Özbay, 2022). Doğruluk ölçütünün hesaplanma yöntemi Denklem 1’de gösterilmektedir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+YN+DN} \quad (1)$$

Kesinlik (Precision)

Pozitif öngörü değeri modelin pozitif olarak sınıflandırdığı örneklerin gerçekte pozitif olma oranını gösteren bir performans ölçütüdür. Bu metrik, gerçek pozitif sayısının toplam pozitif sayısına bölünmesiyle elde edilir ve 0 ile 1 arasında değer alır (Ciran ve Özbay, 2022). Kesinlik değerinin yüksekliği modelin doğruluğu açısından önemli kriterlerdendir. Kesinlik ölçütünün hesaplanma yöntemi Denklem 2’de gösterilmektedir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık (Recall)

Bu ölçüt, tüm gerçek pozitif örnekler içinde modelin doğru biçimde saptadığı kısmı belirleyen ve 0 ile 1 aralığında değer alan duyarlılık (recall) katsayısıdır (Korkmaz, 2021). Duyarlılık ölçütünün hesaplanma yöntemi Denklem 3’te gösterilmektedir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

F1 skor Değeri

Kesinlik ve duyarlılık değerlerinin harmonik ortalamasına dayanan F1 skoru, bir performans ölçütü olarak kullanılmaktadır. Dengesiz sınıf dağılımına sahip veri kümelerinde, performansın daha sağlıklı değerlendirilebilmesi adına doğruluk metriği yerine F1 skorunun kullanılması önerilmektedir (Ciran ve Özbay, 2022). F1 Skor ölçütü hesaplanma yöntemi Denklem 4’te gösterilmektedir.


$$F1\ Skor = 2 \times \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (4)$$




5. BULGULAR VE TARTIŞMA

Bu çalışma iki uygulamadan oluşmaktadır. İlk uygulama olarak insan, nesne (ağaç) ve hayvan (kedi) görüntülerinden yararlanılmıştır. Görüntüler genel olarak değerlendirildiğinde eğitilen modelin başarılı olduğunun kabul görülmesi için birleşim üzerindeki kesişim (IoU) parametresinin 0,5'ten büyük olması gerekmektedir. Bu değerin üstündeki değerler eğitilen modelin başarılı olduğunu göstermektedir. Ancak kesişim parametresi ile ilgili performans parametreleri de bulunmaktadır. Bunlardan doğruluk, modelin tespit doğruluğunu; kesinlik, model tarafından pozitif olarak tahmin edilen girdi görüntülerinin gerçek veri setinin ne kadarının pozitif olduğunu; doğruluk, model tarafından pozitif olarak tahmin edilmesi gereken girdi görüntülerinin ne kadarının doğru tahmin edildiği ile bilgi sunmaktadır (Chen vd., 2023; Xiong vd., 2024).


Doğruluk değeri ve mAP parametresi ile performansın ölçülerek modelin doğruluğunun ve hassasiyetinin bulunması sağlanılmaktadır. İnsan, nesne (ağaç) ve hayvan (kedi) tespitinin sağlıklı bir şekilde yapıldığını ve modele uygun olduğunu analiz edebilmek için modelin eğitilmesi sonucu F1 skoru, duyarlılık ve kesinlik grafikleri elde edilmiştir. Bu değerler çalışmanın ilk uygulamasını ifade etmektedir. Elde edilen değerler sırasıyla Şekil 5.1, Şekil 5.2, Şekil 5.3 ve Şekil 5.4'te gösterilmektedir.




Şekil 5. 1. F1 Skoru- Güven Eğrisi (1. Uygulama)



Şekil 5. 2. Kesinlik Eğrisi (1. Uygulama)




Şekil 5. 3. Duyarlılık Eğrisi (1. Uygulama)



Şekil 5. 4. Kesinlik-Duyarlılık Eğrisi (1. Uygulama)

Sınıflandırma doğruluğu, F1 skor değeri, kesinlik ve duyarlılık değerlerinin haricinde, sınıflandırma algoritmasının performansını özetlemek için karışıklık matrisi kullanılmaktadır. Karışıklık matrisi hem sınıflandırma yapılırken modelin hata oranlarını hem de hatanın türü ile ilgili bilgiler sunmaktadır. Özetle, model tarafından tespit edilmiş görüntüler ile gerçek görüntülerin karşılaştırılması yer almaktadır. İlk uygulamaiçin test kümesine ait karışıklık matrisi Şekil 5.5'te gösterilmektedir.




Şekil 5. 5. YOLOv10 modeline ait karışıklık matrisi (1. Uygulama)

Şekil 5.5'e göre karışıklık matrisinde sütunlar gerçekte sınıfın ne olduğunu, satırlar ise tahmin edilen sınıfı belirtmektedir. Karışıklık matrisinin değerlendirilmesi, sınıflar arasındaki tahmin performansının oransal düzeyde incelenmesine dayanmaktadır. Bu amaçla kullanılan karışıklık matrisi, her bir sınıfa ilişkin gerçek ve tahmin edilen değerlerin yüzdesel dağılımını sunmaktadır. Ayrıca matriste tanımlanan üç ana sınıfın dışında kalan tüm nesne ve yapıları temsil eden bir “arka plan (background)” sınıfının yer aldığı görülmektedir. Bu sınıf sistemin ilgilenmediği veya sınıflandırma kapsamında olmayan öğeleri kapsamaktadır.

Şekil 5.5'e göre insan görüntüsünün yaklaşık %94'ünün doğru bir şekilde model tarafından insan olarak sınıflandırıldığı, kedi görüntüsünün %100'ünün doğru bir şekilde model tarafından kedi olarak sınıflandırıldığı ve ağaç görüntüsünün yaklaşık %99'unun model tarafından ağaç olarak sınıflandırıldığı şeklinde yorumlanabilir.

Sınıflandırılan test kümesine ait insan, nesne (ağaç) ve hayvan (kedi) katman görüntüleri Şekil 5.6'da gösterilmektedir.



Şekil 5. 6. Test veri setindeki tahmin ve katman görüntüleri (1. Uygulama)

Oluşturulan veri tabanı kullanılarak geliştirilen program, Benfold ve Reid'in çalışmalarında kullanılan 5 dakikalık Oxford Sokağı video kaydı üzerinde yeniden çalıştırılmış ve elde edilen sonuçlar doğrulanmıştır. Analizler sonucunda, rastgele seçilen kareler (frame'ler) üzerinde doğruluk oranı %91 olarak hesaplanmıştır (Benfold ve Reid, 2011). Analiz sonuçlarına ait görüntü kesitleri Şekil 5.7'de gösterilmektedir.



Şekil 5. 7. Oxford Sokağı analiz sonuçlarına ait görüntü kesiti

Yapılan çalışmada sınıfların eğitilmesi sonucu Şekil 5.8’de yer alan grafikte eğitim sonuçları program çıktısı olarak gösterilmektedir. Eğitim sonuçlarının yer aldığı grafiklerde,

train/box_om grafiği, modelin eğitim sürecinde nesne konumlandırma doğruluğunu yansıtan koordinat tabanlı kayıp değerinin zamana bağlı olarak nasıl değiştiğini göstermektedir. Eğitimin başlangıç aşamalarında yüksek seviyelerde seyreden bu kayıp değeri, eğitim ilerledikçe (epoch sayısı arttıkça) istikrarlı bir şekilde azalmaktadır. Bu düşüş, modelin gerçek nesne konumlarını tahmin etme yetkinliğinin arttığını göstermektedir.

train/cls_om grafiği, one-to-many (her bir gerçek nesneye karşılık birden fazla tahmin yapılmasına olanak tanıyan başlık yapısı) başlıklar için sınıflandırma kaybıdır. Bu kayıp modelin sınıf tahmininin doğruluğunu yansıtır. Kayıp değeri ne kadar düşüğe modelin sınıflandırma doğruluğu o kadar yüksektir.

train/dfl_om grafiği, one-to-many başlık yapısının çıktısı olan kutu koordinatlarının doğruluğunu ölçer. Modelin tahmin ettiği kutu konumunun, gerçek konuma dağılımsal olarak ne kadar yakın olduğunu ölçer. Eğitim yapıldığı süre boyunca bu değer düşmesi sayesinde model, kutuların konumlarının giderek daha hassas ve kararlı tahmin etmeye başlar.

train/box_oo grafiđi, modelin bir nesne iin yaptıđı tekil (one-to-one) kutu tahmininin, gerek kutuyla ne kadar rtüřtüğünü len kayıp deđeridir. Model eđitimi yapıldıđı süre boyunca bu deđerin düřmesi, modelin kutu tahminlerinde daha dođru olmasını sađlar.

train/cls_oo grafiđi, modelin one-to-one bařlık yapısı altında, tespit ettiđi nesneleri dođru sınıfa atayıp atamadıđını ler. Bu deđer eđitimin bařlangı kısmında yüksektir ünkü model sınıf ayrımını henüz ğrenememiřtir. Eđitim ilerledike model daha dođru sınıflar yapıp bu deđer düřürecektir. Bu deđer düřtüke modelin nesneleri dođru sınıflara atama yeteneđinin geliřtiđini gösterir.


metrics/recall grafiđi, modelin duyarlılık deđerini göstermektedir. Bu deđer, modelin dođru olarak tespit ettiđi gerek pozitif rneklerin, toplam gerek pozitif rnekler iindeki oranını ifade eder. Eđitim ilerledike bu deđerin arttıđı gözlemlenmektedir. Bu artıř, modelin zamanla daha fazla sayıda gerek nesneyi isabetli řekilde tespit edebildiđini göstermektedir.

metrics/mAP50 grafiđi, modelin nesne tespit performansını lmek iin kullanılan Ortalama Doğruluk Deđerini (Mean Average Precision – mAP) gösterir. Bu deđer, Intersection over Union (IoU) eřik deđer 0.5 olarak alınır. Eđitim ilerledike bu deđerde görülen artıř modelin nesneleri daha dođru sınıflandırdıđını göstermektedir.

metrics/mAP50-95 grafiđi, IoU eřik deđerleri 0.5 ile 0.95 arasında deđiřen mAP deđerini göstermektedir. Bu deđer, modelin nesne tespit bařarımının yalnızca belirli bir eřikte deđil, farklı eřik deđerlerinde de olmasına olanak sađlar. Eđitim süresince bu deđerdeki artıř, modelin geniř bir IoU aralıđında yüksek doğrulukta tahminler yapabildiđini göstermektedir.


metrics/precision grafiđi, modelin hassasiyet deđerini göstermektedir. Bu deđer modelin dođru pozitif tahminlerin toplam pozitif tahminlere oranı olarak tanımlanır. Eđitim süresince bu deđerde gözlemlenen artıř modelin sahte pozitif tahminlerini azaltarak dođru nesne tespiti yapabilmesini sađlamaktadır.

train/dfl_oo grafiđi, modelin sınırlayıcı kutularının konumlarını ne kadar dođru tahmin ettiđini ler. Epoch ilerledike bu deđerin düřmesi, modelin kutu tahminlerinde dođru ve kararlı olduđunu göstermektedir.




Şekil 5. 8. YOLOv10 eğitim sonuçları (1. Uygulama)


Modelin 2. Uygulaması olarak insan, nesne (ağaç) ve hayvan (kedi, inek, keçi) görüntülerinden yararlanılmıştır. Doğruluk değeri ve mAP parametresi ile performansın ölçülerek modelin doğruluğunun ve hassasiyetinin bulunması sağlanılmaktadır. İnsan, nesne (ağaç) ve hayvan (kedi, inek, keçi) tespitinin sağlıklı bir şekilde yapıldığını ve modele uygun olduğunu analiz edebilmek için modelin eğitilmesi sonucu F1 skoru, duyarlılık ve kesinlik grafikleri elde edilmiştir. Bu değerler çalışmanın ikinci uygulamasını ifade etmektedir. Elde edilen değerler sırasıyla Şekil 5.9, Şekil 5.10, Şekil 5.11 ve Şekil 5.12’de gösterilmektedir.




Şekil 5. 9. F1 Skoru - Güven Eğrisi (2. Uygulama)



Şekil 5. 10. Kesinlik Eğrisi (2. Uygulama)




Şekil 5. 11. Duyarlılık Eğrisi (2. Uygulama)



Şekil 5. 12. Kesinlik - Duyarlılık Eğrisi (2. Uygulama)

Sınıflandırma doğruluğu, F1 skor değeri, kesinlik ve duyarlılık değerlerinin haricinde, sınıflandırma algoritmasının performansını özetlemek için karışıklık matrisi kullanılmaktadır. Karışıklık matrisi hem sınıflandırma yapılırken modelin hata oranlarını hem de hatanın türü ile ilgili bilgiler sunmaktadır. Özetle, model tarafından tespit edilmiş görüntüler ile gerçek görüntülerin karşılaştırılması yer almaktadır. 2. Uygulama olarak belirtilen modelin eğitilip oluşturulan test kümesine ait karışıklık matrisi Şekil 5.13'te gösterilmektedir.



Şekil 5. 13. YOLOv10 modeline ait karışıklık matrisi (2. Uygulama)

Şekil 5.13'e göre insan görüntüsünün yaklaşık %86'sının model tarafından insan olarak sınıflandırıldığı, kedi görüntüsünün %84'ünün model tarafından kedi olarak sınıflandırıldığı, ağaç görüntüsünün yaklaşık %91'inin model tarafından ağaç olarak sınıflandırıldığı, inek görüntüsünün yaklaşık %89'unun model tarafından inek olarak sınıflandırıldığı ve keçi görüntüsünün yaklaşık %75'inin model tarafından keçi olarak sınıflandırıldığı şeklinde yorumlanabilir. Model, eğitimini tamamladıktan sonra test kümesi için insan, nesne (ağaç) ve hayvan (kedi, inek, keçi) tespiti yapıp tahmin ve katman görüntüleri Şekil 5.14'te gösterilmektedir.




Şekil 5. 14. Test veri setindeki tahmin ve katman görüntüleri (2. Uygulama)

Oluşturulan veri tabanı kullanılarak geliştirilen program ile yeni sınıf olarak analiz ettirilen inek ve keçi görüntülerinden rastgele seçilen kareler (frame'ler) üzerinde doğruluk oranı inek için %96 ve keçi için %57 olarak hesaplanmıştır. Analiz sonuçlarına ait görüntü kesitleri Şekil 5.15 ve Şekil 5.16'da gösterilmektedir.




Şekil 5. 15. İnek görüntülerinin yer aldığı analiz sonuçlarına ait görüntü kesiti



Şekil 5. 16. Keçi görüntülerinin yer aldığı analiz sonuçlarına ait görüntü kesiti

Yapılan çalışmada sınıfların eğitilmesi sonucu Şekil 5.17’de yer alan grafikte eğitim sonuçları program çıktısı olarak gösterilmektedir. Eğitim sonuçlarının yer aldığı grafiklerde, train/box_om grafiğinde epoch arttıkça değerin düştüğü görülmektedir. Bu düşüş, modelin gerçek nesne konumlarını tahmin etme yetkinliğinin arttığını göstermektedir. Train/cls_om grafiğinde, kayıp değerinin epoch arttıkça düştüğünü bu sebeple kayıp değeri ne kadar

düşükse modelin sınıflandırma doğruluğu o kadar yüksek olduğu gözlemlenmektedir. Train/dfl_om grafiğinde yer alan değer epoch arttıkça düşmektedir. Bu sayede model, kutuların konumlarını daha hassas ve kararlı tahmin etmeye başlamaktadır. Train/box_oo grafiğinde, model eğitimi yapıldığı sürece bu değer düşmekte olup modelin kutu tahminlerinde daha doğru olmasını sağlamaktadır. Train/cls_oo grafiğinde, modelin eğitimi yapıldığı sürece bu değer düşmektedir. Bu sayede modelin nesneleri doğru sınıflara atama yeteneğinin geliştiğini göstermektedir. Metrics/recall grafiğinde, modelin eğitimi yapıldığı sürece arttığı gözlemlenmiştir. Bu artış, modelin zamanla daha fazla sayıda gerçek nesneyi isabetli şekilde tespit edebildiğini göstermektedir. Metrics/mAP50 grafiğinde, modelin eğitimi yapıldığı sürece bu değerde görülen artış ile modelin nesneleri daha doğru sınıflandırdığı gözlemlenmiştir. Metrics/mAP50-95 grafiğinde, modelin eğitimi yapıldığı sürece bu değerde gerçekleşen artış ile modelin geniş bir IoU aralığında yüksek doğrulukta tahminler yapabildiği gözlemlenmiştir. Metrics/precision grafiğinde, modelin eğitimi yapıldığı sürece bu değerde artış gözlemlenmiştir. Bu artış ile model, sahte pozitif tahminlerini azaltarak doğru nesne tespiti yapabilmesini sağlamaktadır. Train/dfl_oo grafiğinde, modelin eğitimi yapıldığı sürece değer düşmekte olduğu gözlemlenmiştir. Bu değer düşmesi ile model, kutu tahminlerinde daha doğru ve kararlı olmaktadır.



Şekil 5. 17. YOLOv10 eğitim sonuçları (2. Uygulama)

6. SONUÇ

Yapılan çalışmada yer alan görüntüler YOLOv10 nesne tespit yöntemi ile tespit edilmiştir. İlk olarak belirlenen sınıflar için görüntüler toplanmıştır. Toplanan görüntüler YOLOv10 modeli ile Google Colab altyapısında eğitime başlanmıştır. Eğitilen modellerin etiketleme işlemi Roboflow tarafından yapılmıştır.

Sonuçlar incelendiğinde, 1. Uygulama olarak insan, nesne (ağaç) ve hayvan (kedi) sınıflarının eğitilmesi sonucu doğruluk değeriyle ilişkili olan mAP50 değeri 0.984 olarak elde edilmiştir. Ancak mAP50 değerinde yer alan uç noktalardaki görüntüler değerlendirilmediğinden, F1 skor değeri dikkate alınarak daha doğru sonuçlar vermesine olanak sağlayacaktır. Çalışma için kullanılan model sonucunda F1 skor değeri 0,95 olarak elde edilmiştir. Bu çalışmada elde edilen değer, modelin oldukça başarılı bir şekilde oluşturulup güvenli sonuçlar verdiğini göstermektedir.

Şekil 5.5'te gösterilen 1. uygulama için verilmiş olan karışıklık matrisi değerleri ile Roboflow üzerinden etiketleme işlemi yapılarak, veri seti kümesinin %80'i eğitim ve %20'si test şeklinde eğitimi gerçekleştirildikten sonra insan, nesne (ağaç) ve hayvan (kedi) tespitinin ve sınıflandırılmasında yapılan test kümesi sonuçlarına göre ağaç için %99, insan için %94 ve kedi için %100 doğruluk değeri elde edilmiştir. Bu sonuçlar veri setinin çok yüksek doğruluk değerine sahip olduğunu göstermektedir.

Elde edilen sonuçlarda sınıf sayısının artırılması ile değişikliklerin gözlemlenmesi hedeflenmiştir. Bu kapsamda, 2. uygulama olarak insan, nesne (ağaç) ve hayvan (kedi) sınıf türlerinin yanında inek ve keçi de sınıf türleri olarak eklenmiştir. Belirlenen sınıfların eğitilmesi sonucu doğruluk değeriyle ilişkili olan mAP50 değeri 0.851 olarak, F1 skor değeri 0,82 olarak elde edilmiştir. Bu çerçevede, sınıf sayısının ve görüntü sayısının değişmesi ile eğitim sonuçlarındaki değişiklikler gözlemlenmiştir.

Şekil 5.13'te gösterilen 2. Uygulama için verilmiş olan karışıklık matrisi değerleri ile Roboflow üzerinden etiketleme işlemi yapılarak, veri seti kümesinin eğitimi gerçekleştirildikten sonra insan, nesne (ağaç) ve hayvan (kedi, inek, keçi) tespitinin ve sınıflandırılmasında yapılan test kümesi sonuçlarına göre ağaç için %91, insan için %86, kedi için %84, inek için %89 ve keçi için %75 doğruluk değeri elde edilmiştir.

Her iki uygulamada elde edilen bu değerler, Sadik ve ark. (2024) yayaaların gerek zamanlı tespiti ve analizi zerine yaptıęı YOLOv8I ve RT-DETR-L modellerinin kullanılarak %82,2 ve %81,7'lik mAP deęerinde olan, Algur ve ark. (2018) dıř ortam grntlerindeki insanların hareketlerinin sınıflandırılmasına ynelik yaptıęı konvolsyonel sinir aęı modeli ile %85,71'lik bařarım oranı olan ve Sharma ve ark. (2014) hayvan (kpek) tanımlaması iin eřitli kpek grntleri zerinde yaptıęı ve %86,25'lik bařarım oranı olan alıřma sonularından daha iyi sonular vermektedir.

alıřmanın sonuları dikkate alındıęında, havaalanlarının stratejik konumu hizmet sektrnn nde gelen bir alanı olduęu iin gvenlik ok nemlidir. Havaalanı evre gvenlięi sınır hattı boyunca yerleřtirilen kameralarla saęlanmakla birlikte elde edilen grntler ile sınır hattını ařan ihlaller bildirilmektedir. Yapılan alıřmada, evre hattında belirlenen hayali sınır hattından insan veya hayvan (kedi, inek, kei) gemesi halinde grnt eęitilerek tespit edilip sınıflandırılması yapılmıřtır. Ayrıca belirlenen hayali sınır, grnt zerinden deęiřtirilebilir řekilde yapılmıřtır. İhlal anında yanlış alarm vermemesi iin aęalar da sınıflandırma grubunda yer almaktadır. İhlal tespiti iin insan ve hayvan olarak kedi, inek ve kei de sınıflandırma grubunda yer almıřtır. alıřmanın grnty hem tespit edip hem de sınıflandırma yapması ayrıca grnt ierisinde hayali sınır oluřturulup sınırın geildięinde alarm retmesi ve sınır hattını geen insan ya da hayvan sayısının tespitinin yapılması gibi senaryolar ile kendisini literatrde yer alan dięer alıřmalardan ayrı kılmaktadır.

alıřmada belli sayıda sınıflandırma dikkate alınmıřtır. Yeni bir alıřmada sınıf sayısının arttırılması dřnlebilir. Grnt sayısının arttırılması ile bařarının daha yksek ıkması beklenilmektedir. Ayrıca alarm senaryoları da havaalanına zel olarak deęiřtirilebilir ve uygulanabilir.

KAYNAKLAR

- Abeyratne, R.I.R. (1994). The effects of unlawful interference with civil aviation on world peace and the social order. *Transp. LJ*, 22, 449.
- Agustina, J. R. ve Clavell, G. G. (2011). The impact of CCTV on fundamental rights and crime prevention strategies: The case of the Catalan Control Commission of Video surveillance Devices. *Computer Law & Security Review*, 27(2), 168-174.
- Akmeşe, Ö. F., Çizmeci, H., Özdem, S., Özdemir, F., Deniz, E., Mazman, R., Erdoğan, M. ve Erdoğan, E. (2023). Prediction of gender and age period from periorbital region with VGG16. *Chaos Theory and Applications*, 5(2), 105-110.
- Aktaş, A. (2020). *Derin Öğrenme Yöntemleri İle Görüntü İşleme Uygulamaları*, Yayınlanmamış Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Alemdar, K. D. (2024). Çift sıra parklanma durumunun nesne tespit algoritması YOLOv8 ile tespit edilmesi. *Journal of the Institute of Science and Technology*, 14(3), 1164-1176.
- Algur, Ö., Tümen, V. ve Yıldırım, Ö. (2018). Dış ortam görüntülerindeki insan hareketlerinin hibrit derin öğrenme yöntemleri kullanarak sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 30(3), 121-129.
- Arcúrio, M. S., Pereira, R. R., de Arruda, F. S. (2020). Security culture in the screening checkpoint of Brazilian airports. *Journal of Air Transport Management*, 89, 101902.
- Ayyüce Kızrak, M. ve Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- Barry, A. S. (2018). Guidance for Airport Perimeter Security. *National Safe Skies Alliance, PARAS Project 0015 Final Report*.
- Benfold B., Reid I. (2011). *Stable Multi-Target Tracking In Real-Time Surveillance Video*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 3457–3464.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations And Trends In Machine Learning*, 2(1):1-127.
- Benli, S. N. (2021). *Derin Evrişimli Yapay Sinir Ağı Kullanarak Meyve Yaprağı Hastalık Tespiti*, Yayınlanmamış Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü, Bilecik.
- Bingöl, K., Akan, A. E., Örmecioğlu, H.T. ve Er, A. (2020). *Artificial Intelligence Applications In Earthquake Resistant Architectural Design: Determination Of Irregular Structural Systems With Deep Learning And Imageai Method*.

- Bochkovskiy, A., Wang, C.-Y., Liao, H.-Y.M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv 2020*, arXiv:2004.10934.
- Bozkurt, K. (2021). *Ardışık Sayısal Görüntülerde Çok Sayıda Hareketli Nesnenin Tespiti, İzlenmesi, Tanımlanması ve Sınıflandırılması*, Yayınlanmamış Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Button, K., Clarke, A., Palubinskas, G., Stough, R., Thibault, M. (2004). Conforming with ICAO safety oversight standards. *Journal of Air Transport Management*, 10(4), 249-255.
- Chen Y., Xu H., Zhang X., Gao P., Xu Z., Huang X. (2023). An object detection method for bayberry trees based on an improved YOLO algorithm. *International Journal of Digital Earth*, 16(1), 781-805.
- Chollet, F. (2020). *Python ile Derin Öğrenme*. Ankara: Buzdağı Yayınevi.
- Choubisa, T., Kashyap, M. ve Chaitanya, K. K. (2018). *Human Crawl Vs Animal Movement And Person With Object Classifications Using CNN For Side-View Images From Camera*. 2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI), 48-54.
- Cimpoi, M., Maji, S., Kokkinos, I. ve Vedaldi, A. (2016). Deep filter banks for texture recognition, description, and segmentation. *International Journal of Computer Vision*, 118(1), 65–94.
- Ciran, A. ve Özbay, E. (2022). Ön-eğitilmiş CNN mimarilerinin füzyonu ile mısır yaprağı hastalıklarının sınıflandırılması. *European Journal of Science and Technology*.
- Copeland, M. (2020). What's the Difference Between Artificial Intelligence, Machine Learning and Deep Learning.
- Çalışkan, D. ve Demir, Ö. (2022). Derin öğrenme yöntemleri ile şüpheli davranış tespiti. *International Periodical of Recent Technologies in Applied Engineering*, 3(1), 26-41.
- Çoban, R. ve İpek, S. (2020). Sivil havacılık sektöründe uçuş güvenlik görevlisi uygulamaları üzerine kavramsal bir araştırma. *Journal of Aviation*, 4(1), 89-102.
- Daşkın, Y. Ç., Balık Şanlı, F., Özkan, T. ve Kartal, H. (2018). *Derin Öğrenme Yöntemleri İle Yüz Görüntülerinden Yaş Kestirimi*. VII. Uzaktan Algılama Ve Cbs Sempozyumu Uzal-Cbs2018.
- Davis, A. ve Chang, H. (2012). *Airport Protection Using Wireless Sensor Networks*. 2012 IEEE Conference on Technologies for Homeland Security (HST), 36-42.
- EASA. (2020). *Security Risk Management Manual for Airport Operators*. European Union Aviation Safety Agency.
- Eldem, A., Eldem, H. ve Palalı, A. (2017). Görüntü işleme teknikleriyle yüz algılama sistemi geliştirme. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 6(2), 44-48.
- FAA. (2021). *Advisory Circular 150/5210-24: Airport Foreign Object Debris (FOD)*

Management. Federal Aviation Administration.

- Feng, Q. (2007). On determining specifications and selections of alternative technologies for airport checked-baggage security screening. *Risk Analysis*, 27(5), 1299-1310.
- Frederickson, H. G., LaPorte, T. R. (2002). Airport security, high reliability, and the problem of rationality. *Public Administration Review*, 62, 33-43.
- Gemici, E. ve Yılmaz, H. (2019). Güvenlik stratejileri ve yönetimi açısından havacılık güvenliği. *Journal of Aviation*, 3(1), 15-27.
- Ghiasi, G., Cui, Y., Srinivas, A., Qian, R., Lin, T.-Y., Cubuk, E.D., Le, Q.V., Zoph, B. (2021). *Simple Copy-Paste Is A Strong Data Augmentation Method For Instance Segmentation*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, 20–25 June 2021.
- Gong, Y., Wang, L., Guo, R. ve Lazebnik, S. (2014). Multi-scale orderless pooling of deep convolutional activation features. Lecture Notes in Computer Science (including subseries lecture notes in artificial intelligence and lecture notes in bioinformatics), 8695 LNCS(PART 7, 392–407.
- Graham, A. (2020). *Managing Airports: An International Perspective* (5th ed.). Routledge.
- Hallowell, S. F. (2001). Screening people for illicit substances: A survey of current portal technology. *Talanta*, 54(3), 447-458.
- He, K., Gkioxari, G., Dollár, P., Girshick, R. (2018). *Mask R-CNN*. Proceedings of the IEEE International Conference on Computer Vision, Salt Lake City, UT, USA, 18–23.
- International Air Transport Association (IATA). (2023). Innovation 2023: An Overview.
- İnik, Ö. ve Ülker, E. (2017). Derin Öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Karakuş, Ö. (2006). *Hava Aracı Kaza Ve Kırımlarında İnsan Faktörünün Araştırılması*. Doctora Tezi, Ankara Üniversitesi, Ankara, Türkiye.
- Karaoğlu, B. (2022). *Görüntü İşlemenin Convolutional Neural Network(Cnn) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti*. Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.
- Karasu, E. (2019). *Metin Madenciliği Tekniklerini Kullanarak Faaliyet Bazlı Proje Yönetiminde Bilgi Yönetimi Süreçleri İçin Derin Öğrenme Modeli*. Yayınlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü, İstanbul.
- Kaya, B. ve Demirtaş, M. (2019). Bölgesel kalkınma stratejileri kapsamında havaalanlarının ekonomik etkileri. *Şehir ve Bölge Planlama Dergisi*, 11(1), 55–72.
- Korkmaz, A. (2021). *Derin Öğrenme Teknikleriyle Akciğer Röntgeninden COVID-19*

Hastalığının Tespit Edilmesi. Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitimi Enstitüsü, Karabük.

- Kraemer, S., Carayon, P. ve Sanquist, T. F. (2009). Human and organizational factors in security screening and inspection systems: conceptual framework and key research needs. *Cognition, Technology & Work*, 11(1), 29-41.
- Küçükönel, H. (2001). *Havaalanı güvenliği ve Sabiha Gökçen Uluslararası Havaalanı güvenlik sistemi için bir model önerisi*. Master Tezi, Ankara, Türkiye.
- Liao, L., Song, C., Wu, S., Fu, J. (2025). A novel YOLOv10-based algorithm for accurate steel surface defect detection. *Sensors*, 25, 769.
- Lin, T. Y., RoyChowdhury, A. ve Maji, S. (2015). *Bilinear CNN Models For Fine-Grained Visual Recognition*. Proceedings of the IEEE international conference on computer vision, 1449–1457.
- Lin, T. Y., Goyal, P., Girshick, R., He, K., Dollar, P. (2017). *Focal Loss For Dense Object Detection*. Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 22–29 October 2017; IEEE: Piscataway, NJ, USA, 2999–3007.
- Liu, S., Qi, L., Qin, H., Shi, J. ve Jia, J. (2018). *Path Aggregation Network For Instance Segmentation*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 18–23 June 2018.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y. ve Berg, A.C. (2016). *SSD: Single Shot Multibox Detector*. Proceedings of the Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, 11–14 October 2016, 21–37.
- Lykou, G., Moustakas, D. ve Gritzalis, D. (2020). Defending airports from UAS: A survey on cyber-attacks and counter-drone sensing technologies. *Sensors*, 20(12), 3537.
- Naes, M. (2023). *Glokom Hastalığının Derin Öğrenme Yöntemiyle Ön Tanısı*. Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük.
- Nayak, R., Behera, M. M., Pati, U. C. ve Das, S. K. (2019). *Video-Based Real-Time Intrusion Detection System Using Deep-Learning For Smart City Applications*. 2019 IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS), 1-6.
- Oh, G., Ryu, J., Jeong, E., Yang, J. H., Hwang, S., Lee, S. ve Lim, S. (2021). Drer: Deep learning– based driver’s real emotion recognizer. *Sensors*, 21(6), 1–29.
- Önal, O. ve Dandıl, E. (2021). Object detection for safe working environments using YOLOv4 deep learning model. *Avrupa Bilim ve Teknoloji Dergisi*, 26, 343-351.
- Özdemir, A. ve Yıldız, M. (2021). Havaalanı güvenlik sistemlerinde yapay zekâ uygulamaları. *Havacılık ve Uzun Teknolojileri Dergisi*, 14(2), 87–101.

- Plante, W. (2024). Addressing ethical and privacy issues with physical security and AI. *Security Management Magazine*, Nisan 2024.
- Prajapati, S. A., Nagaraj, R. ve Mitra, S. (2019). *Proceedings - 6th International Symposium on Computational and Business Intelligence*, ISCBI 2018.
- Pütz, O. (2012). From non-places to non-events: The airport security checkpoint. *Journal of Contemporary Ethnography*, 41(2), 154-188.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. (2016). You only look once: Unified, real-time object detection, 1506.02640.
- Rekiel, J. ve de Wit, J. (2013). The security system at European airports—Tour d’Horizon. *Journal of Transportation Security*, 6(2), 89-102.
- Sadik, M. N., Hossain, T. ve Sayeed, F. (2024). Real-time detection and analysis of vehicles and pedestrians using deep learning. *arXiv preprint*, 2404.08081.
- Sayın, A. K. (2011). *Sivil Havacılık Güvenliğinde Özel Güvenlik Hizmetlerinin Etkinliğinin İncelenmesi (Esenboğa Havalimanı Örneği)*. Yayınlanmamış Yüksek Lisans Tezi. Ankara: Polis Akademisi.
- Sevi, M. ve Aydın, İ. (2023). Detection of foreign objects around the railway line with yolov8. *Computer Science*, (IDAP-2023), 19-23.
- Shang, K., He, C., Zhou, J., Ling, P., Lu, X., Fu, C., ... Yang, T. (2023). Optical and electrical dual-mode tactile sensor with interlinked interfaces recording normal force and slip for closed-loop robotics. *Chemical Engineering Journal*, 475, 146279.
- Shanks, N. E. ve Bradley, A. L. (2004). *Handbook Of Checked Baggage Screening: Advanced Airport Security Operation*. London: Professional Engineering.
- Sharma, S., Shah, D., Bhavsar, R., Jaiswal, B. ve Bamniya, K. (2014). *Automated Detection Of Animals In Context To Indian Scenario*. 2014 5th International Conference on Intelligent Systems, Modelling and Simulation, 334-338.
- Singh, S. ve Singh, M. (2003). Explosives detection systems (EDS) for aviation security. *Signal Processing*, 83(1), 31-55.
- Sivil Havacılık Genel Müdürlüğü (SHGM). (2009). *Tüm Hava Alanları Giriş Kartı Talimatı*. Ankara.
- Sivil Havacılık Genel Müdürlüğü (SHGM). (2015). *Milli Sivil Havacılık Güvenlik Programı Ve Ekleri*. Ankara.
- Skorupski, J. ve Uchroński, P. (2015). A fuzzy reasoning system for evaluating the efficiency of cabin baggage screening at airports. *Transportation Research Part C: Emerging Technologies*, 54, 157-175.
- Sochor, E. (1991). *The Politics Of International Aviation*. London: Macmillan.

- Şamlı, R. ve Yüksel M. E. (2009). *Biometrik Güvenlik Sistemleri*. Akademik Bilişim'09-XI Akademik Bilişim Konferansı Bildirileri'nde sunulan bildiri. Harran Üniversitesi, Şanlıurfa.
- Şeker, A., Di ri, B. ve Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Şimşek, E., Özyer, B. ve Özyer, G. T. (2020). Foto-kapan görüntülerinde derin öğrenme tabanlı insan tespiti. *Bayburt Üniversitesi Fen Bilimleri Dergisi*, 3(1), 1-8.
- Tan, M., Pang, R., Le, Q.V. (2020). *Efficientdet: Scalable And Efficient Object Detection*. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 14–19 June 2020, IEEE: Piscataway, NJ, USA, 10778–10787.
- Tiryaki, F. (2013). *Zabıta Ve Özel Güvenlik Hizmetlerinin Kontrol Merkezleri Yardımıyla İncelenmesi: Kocaeli Uygulaması*.
- Topak, Ö. E., Bracken-Roche, C., Saulnier, A. ve Lyon, D. (2015). From smart borders to perimeter security: The expansion of digital surveillance at the Canadian borders. *Geopolitics*, 20(4), 880-899.
- Transportation Security Administration (TSA). (2004). *Security Guidelines For General Aviation Airports*. USA.
- Ultralytics. Roboflow Entegrasyonu. Ultralytics Dokümantasyon. URL: <https://docs.ultralytics.com/tr/integrations/roboflow/>. Son Erişim Tarihi: 25.03.2025.
- Uzuner, A. (2003). *Sivil Havacılık Güvenliği*. Ankara: Özen Yayıncılık.
- Ünal, Y. (2024). *Derin Öğrenme Yöntemleri İle Asma Yaprak Hastalıklarının Sınıflandırılması*, Yüksek Lisans Tezi, Amasya Üniversitesi Fen Bilimleri Enstitüsü.
- Varghese, R., Sambath, M. (2024). YOLOv8: *A Novel Object Detection Algorithm With Enhanced Performance And Robustness*. Proceedings of the 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS), Chennai, India, 18–19 April 2024; IEEE: Piscataway, NJ, USA, 1–6.
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., Ding, G. (2024). YOLOv10: Real-time end-to-end object detection. *arXiv*, 2405.14458.
- Wells, A. T. ve Young, S.B. (2011). *Airport Planning And Management*. New York, NY: McGraw-Hill.
- Willemsen, B. ve Cadee, M. (2018). Extending the airport boundary: Connecting physical security and cybersecurity. *Journal of Airport Management*, 12(3), 236-247.
- Xiong J., Wu J., Tang M., Xiong P., Huang Y., Guo H. (2024). Combining YOLO and background subtraction for small dynamic target detection. *The Visual Computer*, 1-10.

- Yabanova, İ. ve Kaya, K. (2019). Kaynak değeri olan yaban hayvanlarının görüntü işleme tekniği ile tespiti ve sayımı. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(2), 174-187.
- Yıldırım, O., Günay, F. B. ve Yağanoğlu, M. (2023). Makine öğrenmesi yöntemleriyle orman yangını tahmini. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(3), 1468-1481.
- Yıldız, A., Sarıcioğlu, P. ve Soyluk, A. (2023). Havalimanlarındaki terör saldırılarına karşı alınabilecek önlemlerin mimari açıdan değerlendirilmesi. *The Journal Of International Social Research*, 16(99).
- Young, B. E. (2003). Responsibility and liability for unlawful interference in international civil aviation. *Air Space L.* 28, 1.
- Zhou, X., Wang, D., Krähenbühl, P. (2019). Objects As Points. *arXiv*, 1904.07850.

ÖZGEÇMİŞ

Adı-Soyadı Ümit YEŞİLYURT

Eğitim Derecesi	Okul/Program	Mezuniyet Yılı
------------------------	---------------------	-----------------------

Lisans	Tokat/Gaziosmanpaşa Üniversitesi Mekatronik Mühendisliği	2017
--------	--	------

İş Deneyimi/Yıl	Çalıştığı Yer
2009 - 2013	Kars/Susuz Kazım Karabekir Anadolu Öğretmen Lisesi

2013 - 2017	Tokat Gaziosmanpaşa Üniversitesi
-------------	----------------------------------

2017 - 2018	Bursa Reva Plastik Vakum A.Ş.
-------------	-------------------------------

2020 - 2021 Ltd.Şti.	Bursa Özlü Mühendislik Proje Taahhüt Makine San.Tic.
-------------------------	--

2021 - Halen	Ankara Devlet Hava Meydanları İşletmesi Genel Müdürlüğü
--------------	---

Yabancı Dil İngilizce

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) Yeşilyurt Ü., ve Aydın Yurdusev A. (2025). Runway Intrusion Detection with YOLOv10: Deep-Learning Based Approach. Journal of Engineering Research and Applied Science, (Kabul Edildi).