



Mühendislik Alanında Akademik Araştırma ve Derlemeler II

Editör

Prof. Dr. Birol KILIÇ

Mühendislik Alanında Akademik Araştırma ve Derlemeler

II

Editör

Prof. Dr. Birol KILIÇ

İmtiyaz Sahibi
Platanus Publishing®

Editör
Prof. Dr. Birol Kılıç

Kapak & Mizanpaj & Sosyal Medya
Platanus Yayın Grubu

Birinci Basım
Aralık, 2023

Yayımcı Sertifika No
45813

Matbaa Sertifika No
47381

ISBN
978-625-6634-06-0

©copyright
Bu kitabın yayım hakkı Platanus Publishing'e aittir.
Kaynak gösterilmeden alıntı yapılamaz, izin
alınmadan hiçbir yolla çoğaltılamaz.

Adres: Natoyolu Cad. Fahri Korutürk Mah. 157/B,
06480, Mamak, Ankara, Türkiye.
Telefon: +90 312 390 1 118
web: www.platanuskita.com
e-mail: platanuskita@gmail.com



PLATANUS PUBLISHING®

İçindekiler

BÖLÜM 1.....	9
GÖRSEL DÖNÜŞTÜRÜCÜLERİN GLOKOM TEŞHİSİNDEKİ ETKİSİ	
Doç. Dr. Abdurrahim AKGÜNDÖĞÜ	
BÖLÜM 2.....	27
ÇELİKLER İÇİN ISIL İŞLEME UYGUN TASARIMIN TEMEL PRENSİPLERİ	
Prof. Dr. Volkan KOVAN	
Doç. Dr. Tuğçe TEZEL	
BÖLÜM 3.....	37
METALLERİN SERT LEHİMLENMESİ VE LEHİME UYGUN TASARIM PRENSİPLERİ	
Prof. Dr. Volkan KOVAN	
Doç. Dr. Tuğçe TEZEL	
BÖLÜM 4.....	49
SU KİRLİLİĞİ VE ATIK SU ARITIMI: ANALİZ, SINIFLANDIRMA VE ÇEVRESEL ETKİLER	
Prof. Dr. M. Yunus PAMUKOĞLU	
BÖLÜM 5.....	67
ENERJİ DÖNÜŞÜMÜNDE YENİLİKÇİ YOLCULUK: YENİLENEBİLİR ENERJİ ENTEGRASYONU VE AKILLI ENERJİ DEPOLAMA ÇÖZÜMLERİ67	
Atakan YILDIRIMİsmet TIKIZ	
BÖLÜM 6	
SİLİKON YUMUŞATICILAR VE EKOLOJİK ALTERNATİFLERİ	
Öğr. Gör. Dr. Ahmet Özgür AĞIRGAN	
BÖLÜM 7	
CNC FREZE TAKIMLARI	
Dr. Öğr. Üye. Selim BACAK	
BÖLÜM 8	
MUZ LİFİ TAKVİYELİ POLİOLEFİNLERİN ERİYİK AKIŞ İNDEKSLERİNDEKİ DEĞİŞİMLERİN İNCELENMESİ	
115	
Doç. Dr. Yılmaz KISMET	
Serhat GÜRAY	

BÖLÜM 9..... 125

CO₂ YAKALAMA VE KULLANMA TEKNOLOJİLERİ

Dr. Öğr. Üyesi Gamze GÜNDÜZ MERİÇ

BÖLÜM 10..... 139

**DALGA ENERJİSİNİN KULLANIM ALANLARININ VE TÜRKİYE’DEKİ
KONUMUNUN İNCELENMESİ**

İsmail Uğur USLU

Arş. Gör. Sayit ÖZBEY

Dr. Öğr. Üyesi İsmet TIKIZ

BÖLÜM 11..... 155

**GÜNEŞ ENERJİSİ SİSTEMLERİNE AİT FOTOVOLTAİK PİLLERİN VE PANELLERİN
ÇEVRESEL ETKİLERİNİN İNCELENMESİ**

Prof. Dr. Zeynep ZAIMOĞLU

Prof. Dr. Reyhan ERDOĞAN

BÖLÜM 12..... 179

**TARIM TOPRAKLARINDAKİ EMİSYONLARIN AZALTILMASI VE
TOPRAK YÖNETİMİ**

Prof. Dr. Zeynep ZAIMOĞLU

Prof. Dr. Reyhan ERDOĞAN

BÖLÜM 13..... 201

**TÜFEK/SİLAH BİLEŞENLERİNİN ÖMÜR GELİŞTİRME ÇALIŞMALARI İÇİN
GÜNCEL KAPLAMA ETKİLERİ**

Musa GÜDER

Abdullah ÇELER

Prof. Dr. Mehmet BAĞCI

BÖLÜM 14..... 221

BİYOSERAMİK DOLGULU DENTAL KOMPOZİT RESTORATİF MALZEMELER

Prof. Dr. Nurcan ÇALIŞ AÇIKBAŞ

Doç. Dr. Gökhan AÇIKBAŞ

BÖLÜM 15.....243

KAMİKAZE İHA'LARDA DERİN ÖĞRENME TABANLI HEDEF TESPİTİ VE TAKİBİ

Erdem CAN

Bedirye İkbāl KIRKLAR

Doç. Dr. Mustafa NAMDAR

Dr. Öğr. Üyesi Arif BAŞGÜMÜŞ

BÖLÜM 16.....255

**YAPAY ZEKA TABANLI FATURA ANOMALİ TESPİTİ İLE FİNANSAL GÜVENLİĞİ
ARTTIRMA**

İlker YILDIZ

Ayberk Emin KOTAN

Ayşe Berna ALTINEL

BÖLÜM 17.....273

**ÇALIŞANLARIN ETKİNLİĞİNİN DEĞERLENDİRİLMESİ: VERİ ZARFLAMA
ANALİZİ YAKLAŞIMI**

Öğr. Gör. Dr. Deniz DEMİRCİOĞLU DİREN

Arş. Gör. Merve ŞİŞÇİ

BÖLÜM 18.....287

**HARRİS ŞAHİNLERİ OPTİMİZASYONU VE YAPAY SİNİR AĞLARI İLE KURU
ÜZÜM SINIFLANDIRMASI**

Arş. Gör. Merve ŞİŞÇİ

Öğr. Gör. Dr. Deniz DEMİRCİOĞLU DİREN

BÖLÜM 19.....299

YAPAY ZEKÂ ÜRETKENLİK ARAÇLARI

Dr. Öğr. Üyesi Hakan YÜKSEL

BÖLÜM 20.....313

**E-POSTA DOLANDIRICILIK YÖNTEMLERİNİN SİBER GÜVENLİK AÇISINDAN
İNCELENMESİ**

Dr. Öğr. Üyesi Semih ÇAKIR

BÖLÜM 21.....323

SCİLAB VE MÜHENDİSLİK UYGULAMALARI

Prof. Dr. Kanat Burak BOZDOĞAN

Dr. Öğr. Üyesi Erdiñç KESKİN

BÖLÜM 22 345

**RAFİNERİDE HSFO SÜLFÜR GİDERME ÜNİTESİ TASARIMI MODELLEME
ÇALIŞMASI**

Dr. Yelda ALTINSOY

BÖLÜM 23 357

NADİR TOPRAK,ELEMENTLERİ METALURJİSİ

Dr. Öğr. Ü. Güven YARKADAŞ

Doç. Dr. Hüseyin ŞEVİK

BÖLÜM 24 371

TEKSTİL ENDÜSTRİSİNDE SÜRDÜRÜLEBİLİRLİK ve TEMEL KAVRAMLAR

Dr. Öğr. Üyesi Güler ÖNCÜ

Doç. Dr. Meruyert KAYGUSUZ

BÖLÜM 25 385

BAZI GÜVENLİK ALGORİTMALARININ UYGULAMALARI

Dr. Öğr. Üyesi Muammer AKÇAY

Seyit Ahmet ÖZDEMİR

BÖLÜM 26 391

**UYDU GÖRÜNTÜLERİ KULLANILARAK ASKERİ UÇAK TANIMA VE
SINIFLANDIRMA**

Dr. Öğr. Üyesi Muammer AKÇAY

Tolgahan ÇOBANOĞLU

BÖLÜM 27 403

**TRAKTÖR EMNİYET ÇERÇEVESİ DEVRİLME DİRENCİNİN BİLGİSAYAR
ORTAMINDA ANALİZİ**

Prof. Dr. Mehmet ÇALIŞKAN

Prof. Dr. Kemal ERMİŞ

Prof. Dr. Murat KARABEKTAŞ

BÖLÜM 28 403

**GIDA ÜRÜNLERİNDEKİ PESTİSİT KALINTILARININ AZALTILMASINA YÖNELİK
MEVCUT EVDE VE SANAYİDE UYGULANAN İŞLEMLER**

Doç. Dr. Fatma HEPSAĞ

Damla TAŞKIN

BÖLÜM 29.....403

NARENCİYE ATIKLARINDAN D-LİMONEN: A REVIEW

Doç. Dr. Fatma HEPSAĞ

Damla TAŞKIN

BÖLÜM 15

KAMİKAZE İHA'LARDA DERİN ÖĞRENME TABANLI HEDEF TESPİTİ VE TAKİBİ

Erdem CAN¹

Bedirye İkbāl KIRKLAR²

Doç. Dr. Mustafa NAMDAR³

Dr. Öğr. Üyesi Arif BAŞGÜMÜŞ⁴

¹ Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü
ORCID: 0009-0006-2155-7758

² Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü
ORCID: 0009-0000-5479-7674

³ Kütahya Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü
ORCID: 0000-0002-3522-4608

⁴ Bursa Uludağ Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü
ORCID: 0000-0002-0611-3220

GİRİŞ

İnsansız hava araçlarının (İHA) askeri, hobi, ticari ve bilimsel amaçlı kullanımları tüm dünyada hızla artmaktadır. İHA'ların askeri alanda kullanılan türlerinden biri de Kamikaze insansız hava araçlarıdır. Kamikaze İHA'lar (KİHA) üzerinde değişken miktarda patlayıcı bulunan ve genelde operatör veya yapay zekâ ile kontrol edilebilen, modeline göre değişiklik göstererek sürü zekâsına sahip olabilen, genel maksadı düşman birimlerine dalış yaparak hem kendini hem de düşman birimlerini imha edebilen İHA çeşididir [1]. Otonom olarak hedef tanımlama, izleme, manevra yapma gibi çeşitli askeri görevler için kullanılmaktadır. Kamikaze İHA ile hedef otonom bir şekilde takip edilebilir. Bu takip, derin öğrenme algoritmaları ve görüntü işleme teknikleri kullanılarak yapılır. Kamikaze İHA'nın kamerasından alınan görüntüler, derin öğrenme algoritmaları ile analiz edilerek, hedeflerin tespit ve takibi yapılmaktadır. Tespit edilen hedefler, hareket ve dalış algoritmalarıyla imha edilmektedir. Hedeflerin hızlı ve yüksek doğrulukta tespitinin gerçekleşmesi, statik veya hareket halindeki hedeflerin imhasında büyük rol oynamaktadır.

Literatürde, İHA'lar üzerinde hedef tanıma, tespit ve takip sistemlerinin derin öğrenme algoritmaları ile yapıldığı gözlenmektedir [2-4]. İHA'larda hedef tespit ve takip sistemi için kullanılan, derin öğrenmenin nesne algılama mimarisinden olan Faster R-CNN [2] ve [3]'te sunulmuştur. [4]'te Faster R-CNN (Region-based Convolutional Neural Network) ResNet101 modeli kullanılarak silah tespiti yapılmıştır. NCSIST Chien Hsiang isimli delta kanatlı Kamikaze İHA'nın terminal saldırı dalış analizi, [5]'te aktarıldığı üzere, aerodinamik özellikler, açılma analizi ve güç uçuş analizi parametrelerinden oluşmaktadır.

KİHA'nın, derin öğrenme yardımıyla hedeflerini tam isabetle vurabilmesi için hedeflerin, tespit ve takibinin hızlı ve yüksek doğruluk oranında olması gerekmektedir. Bu çalışma için, KİHA'nın potansiyel hedeflerini tanıyabilmesi amacıyla oluşturulan veri setinde insan, 4x4 pickup, tank, gemi ve uçak gibi 5 farklı nesnenin görüntülerinden yararlanılmaktadır. Hedef tespitinde, literatürde sıklıkla kullanılan Faster R-CNN mimarisinden olan ResNet101 algoritması kullanılmaktadır. Hazırlanan veri seti ile Faster R-CNN ResNet101 modelinin makine öğrenimi eğitimleri yapılmaktadır. Modelin eğitim aşamasında, kutu sınıflandırma kaybı, lokalizasyon kaybı, RPN (Region proposal network) nesnellik kaybı, RPN lokalizasyon kaybı, toplam kayıp ve eğitimde kullanılan model hakkında bilgi verilmektedir. Model eğitiminin sonunda yapılan testler ile


eğitimin başarı durumu değerlendirilmektedir. Başarı kriterlerini sağlayan model, Gazebo simülasyon ortamında KİHA olarak kullanılacak İris model İHA'ya aktarılmaktadır.

Çalışmada, KİHA tarafından derin öğrenme yöntemiyle tespit edilen hedefin, hızlı, düşük hata payında ve yüksek doğrulukta imha edilebilmesi için, gerekli olan dalış açısı analizi, aerodinamik performans analizi ve güç uçuş analizi gerçekleştirilmektedir. Analizi yapılan sistemler benzetim ortamında test edilmekte ve İHA'dan gerekli telemetri verileri alınmaktadır.

Çalışmanın 2. bölümünde ResNet101 algoritması ve derin öğrenme modelinin eğitim aşamaları detaylı olarak aktarılmaktadır. Ayrıca modelin sonuç grafikleri Tensorboard üzerinden sunulmaktadır. İHA için detaylı dalış analizi 3. bölümde verilmektedir. Aynı bölümde MATLAB yardımı ile gerçekleştirilen benzetim sonuçları yer almaktadır. Simülasyon için geliştirilen dalış algoritması ve MATLAB tabanlı İHA uçuş günlüğü analizci uygulaması (Flight Log Analyzer) ile İHA telemetri verileri bölüm 4'ün içeriğini oluşturmaktadır. Son bölümde ise elde edilen sonuçlar değerlendirilmektedir.

DERİN ÖĞRENME SİSTEM MODELİ

Bu bölümde, KİHA'nın hedef tespit ve takip işlemleri aktarılmaktadır. Nesnelerin tespiti için, literatürde de yaygın olarak kullanılan, Faster R-CNN ResNet101 modelinden faydalanılmıştır. Şekil 1'de İris model İHA'nın hedef tespit anı modellenmiştir.




Şekil 1. Kamikaze İHA Hedef Tespit Sistem modeli.

A. Faster R-CNN ResNet101 Mimarisi

Faster R-CNN mimarisi iki yapıdan oluşmaktadır. Bölge öneri algoritması olarak RPN'den (Region Proposal Network) ve dedektör ağı olarak Faster R-CNN (box classifier)'den meydana gelmektedir [6]. Bu model, RPN ile örnekleme katmanına direkt bağlı olduğundan, görüntüde nesne tespit işlemi daha çabuk bir şekilde yerine getirilebilmektedir [7].

Faster R-CNN mimarisinden olan ResNet101 algoritması, 101 katman içeren belirli bir sinir ağı (neural network) türüdür [8-9]. Şekil 2'de görüldüğü üzere, x katman girdisini toplama işlemine taşıyan düz çizgi Residual Block (artık bağlantı, kısayol bağlantısı) olarak adlandırılmaktadır. Kısayol bağlantısı kullanmadan önce, x girdisi katmanın ağırlıklarıyla çarpılır ve bir ön yargı terimi eklenir. Ardından, $f(x)$ ReLu aktivasyon fonksiyonundan geçer ve $H(x)$ denklem (1)'deki gibi gösterilen bir çıktı elde edilir [8-11].



Şekil.2. Artık öğrenme bloğu (residual learning block) [7].

$$H(x) = f(wx + b), H(x) = f(x) \quad (1)$$

Öte yandan, kısayol (artık) bağlantısı ile elde edilen çıktı, (2)'de gösterilmektedir.

$$H(x) = f(x) + x \quad (2)$$

Artık blok, aynı sayıda çıktı kanalına sahip 3 x 3 evrişimli katmana sahiptir. Her bir evrişimli katman, bir toplu normalleştirme katmanı ve bir ReLu aktivasyon fonksiyonu izler. Ardından, bu iki evrişim işlemi atlanıp, girdi doğrudan son ReLu aktivasyon fonksiyonundan önce eklenir. Bu tür bir tasarım, iki evrişimli katmanın çıktısının, girdiyle aynı şekle sahip olmasını gerektirir. Böylece birlikte toplanabilirler [6].


ResNet mikro mimari modülü, yapısı ile diğer mimarilerden ayrılır. Bazı katmanlar arasındaki değişim göz ardı edilerek, alt katmana geçiş işlemi

yapılması tercih edilir [7]. ResNet mimarisinde bu duruma izin verilerek hedeflerin tespitinde yüksek doğruluk sağlanır.


B. Faster R-CNN ResNet101 Mimarisi ile Hazırlanan Veri Setinin Eğitilmesi

Makine öğrenmesi için kullanılan model, KİHA'nın hedef olarak görebileceği 5 farklı nesneyi tespit etmek için eğitilmiştir. Eğitim, Linux Ubuntu 20.04 işletim sisteminde merkezi işlem birimi (central processing unit, CPU) ile 53 saat 52 dakika sürmüştür. Eğitimin hazırlık aşamasında, Anaconda programı kurularak, Python çevresi oluşturulmuştur. Tensorflow, matplotlib, numpy, pandas, protobuf, pillow, lxml ve OpenCV kütüphanelerinden yararlanılarak eğitim yapılmıştır. Veri seti hazırlanırken, KİHA'nın hedef olarak görebileceği nesnelerin fotoğrafları internet ortamından ve askeri tatbikatlardan edinilmiştir. Şekil 3a'da veri setinde kullanılan fotoğraflara ait görüntüler sunulmuştur. Şekil 3b'de ise simülasyon ortamında, İris model İHA'dan alınan kamera görüntüleri gösterilmiştir.

Veri setindeki fotoğraflar, LabelImg programı ile PascalVOC formatında etiketlenip .xml dosya formatına çevrilmiştir. Xml dosyaları .csv formatına çevrildikten sonra, fotoğrafların %75'i train dosyasına %25'i test dosyasına aktarılmıştır. Csv formatındaki dosyalar generate_tfrecord.py dosyasına (modüle girdi olarak) verilebilmesi için record formatına dönüştürülmüştür. Nesne isimlerinin sınıflandırıldığı labelmap.pbtxt dosyası oluşturulmuştur. Makine öğrenimi için son aşama olan, faster_rcnn_resnet101_pets.config dosyası üzerinde gerekli ayarlamalar yapıp, makine öğrenimi başlatılmıştır.



Şekil. 3a) Veri seti içinde bulunan görüntüler.




Şekil. 3b) Simülasyon ortamında, İris model İHA'dan alınan kamera görüntüleri.

C. Eğitimi Tamamlanan Modelin Test Sonuçları

KİHA'nın, hedefini tespit ve takip edebilmesi için, hazırlanan 5 nesnenin eğitim ve test aşamalarında kullanılmak üzere 2427 fotoğraf kullanılmıştır. Toplam fotoğrafların %75'i olan 1821 fotoğraf eğitim aşamasında, geri kalan %25'i olan 606 fotoğraf ise test aşamasında kullanılmıştır. Eğitim 30620 adımda tamamlanmıştır. Eğitimin belirli aralıklarında Tensorboard üzerinden kutu sınıflandırma kaybı (box classifier classification loss) değerleri takip edilmiştir. En son adımda, Şekil 4a'daki kayıp değerleri %0.00044958 olduğunda işlem durdurulmuştur.

Loss fonksiyonu, kullanılan modelin tahmini ile gerçek değerinin arasındaki farkı ifade etmektedir [4]. Şekil 4a, tespit edilen nesnelerin sınıflandırılmasına yönelik kaybı göstermektedir. Faster R-CNN ResNet101 modelinin tahminlerinin başarılı olduğu, Şekil 4a'daki loss fonksiyon grafiğinin %0.00044958'e yani 0'a yaklaşmış olduğundan anlaşılmaktadır. Şekil 4a, 4b, 4c, 4d ve 4e'deki soluk çizgiler orijinal kayıpları gösterirken, kalın çizgiler düzeltme faktörünün 0.9'a eşit olduğu düzeltilmiş kayıpları göstermektedir.




Şekil. 4a) Kutu sınıflandırma kaybı (Loss/BoxClassifierLoss/classification_loss)

Box-classifier (kutu sınıflandırıcı) modelinin iki çıkışı bulunmaktadır. Biri, her kutunun hangi sınıfa ait olduğunu belirlemek için kullanılır. Diğeri ise kutu koordinatlarının regresyonu için kullanılır [6]. Kutu sınıflandırma kaybının 30620. adımda %0.00044958'e kadar düştüğü Şekil 4a'da, lokalizasyon kaybının ise 30620. adımda %0.0030589'a kadar düştüğü Şekil 4b'de görülmektedir.




Şekil. 4b) Lokalizasyon kaybı (Loss/BoxClassifierLoss/localization_loss)

RPN modelinin de iki çıkışı bulunmaktadır. Biri nesne olup olmadığını sınıflandırmak için kullanılır. Diğeri ise sınırlayıcı kutu koordinatlarının regresyonu için kullanılır [6]. RPN nesnellik kaybının 30620. adımda %0.00025202'ye kadar düştüğü Şekil 4c'de, RPN lokalizasyon kaybının ise 30620. adımda %0.0054554'e kadar düştüğü Şekil 4d'de görülmektedir.




Şekil. 4c) RPN nesnellik kaybı (Loss/RPNLoss/objectness_loss)



Şekil. 4d) RPN lokalizasyon kaybı (Loss/RPNLoss/localization_loss)

Toplam kayıp, RPN kayıplarının ve kutu sınıflandırma kayıplarının toplamını ifade eder [6]. Toplam kaybın 30620. adımda %0.0092159 seviyesine düştüğü Şekil 4e’de görülmektedir.




Şekil. 4e) Toplam kayıp (Total Loss)

Faster R-CNN ResNet101 modeli kullanılarak, CPU ile yapılan makine öğrenimi, Şekil 4a, 4b, 4c, 4d ve 4e’de görüldüğü üzere, düşük kayıp değerleri ile sonuçlanmıştır. Kayıp değerler, eğitim boyunca zaman zaman artış gösterse de, düzeltme faktörünün 0.9 olduğu kalın çizgilerde, adım sayısı arttıkça ortalama düşüş gösterdiği görülmektedir. Faster R-CNN ResNet101 modelinin, hazırlanan veri setindeki fotoğrafları tahmin etmede başarılı olduğu Şekil 4a’da gözlenmektedir.


DERİN ÖĞRENME YARDIMLI HEDEF TESPİTİ VE TAKİBİ

Bu bölümde, KİHA’nın potansiyel hedeflerini tam isabetle vurabilmesi için, eğitilen 5 nesnenin derin öğrenme modeliyle, tespit ve takibi sunulmaktadır. Eğitimi tamamlanan modelin, fotoğraflar ve video takip sistemi üzerinden testleri

gerçekleştirildikten sonra başarı yüzdeleri analiz edilmiştir. Eğitimi tamamlanan modelin, KİHA'lar için hazırlanan veri setindeki potansiyel hedefleri tespit etmede başarılı olduğu Şekil 5a'da tespit yüzdeleri ile görülmektedir. Başarı kriterlerini sağlayan derin öğrenme modeli, bir sonraki aşama olan Gazebo simülasyon ortamında İris model İHA'nın kamera istemcisine aktarılmıştır. OpenCV kütüphanesi yardımıyla ve ROS (Robot Operating System) aracılığıyla İris model İHA kamerasında testleri gerçekleştirilmiştir. İris model İHA'nın, tespit edilen hedefleri dalış algoritmalarıyla imha etmesinin planlandığı bazı hedefler Şekil 5b'de tespit yüzdeleri ile aktarılmaktadır.



Şekil. 5a) Faster R-CNN ResNet101 modelinin potansiyel hedefler üzerinde doğruluk oranları.



Şekil. 5b) Faster R-CNN ResNet101 modelinin, İris model İHA kamerasında, potansiyel hedefler üzerinde doğruluk oranları.

SONUÇ

Bu çalışmada, KİHA'ların hedeflerini tespit ve takip edebilmesi amacıyla Faster R-CNN ResNet101 modeli kullanılmıştır. Bu amaçla derin öğrenme modelinin eğitilmesi ve test edilmesi için veri seti hazırlanmış ve makine öğrenimi gerçekleştirilmiştir. Derin öğrenme modelinin, her bir karedeki başarılı hedef tespit dereceleri video takip sistemi üzerinden incelenmiştir. Elde edilen çıktıların, makine öğrenimi yapılan veri setine, video çeşitlerine vb. özelliklere bağlı olarak değişkenlik gösterebileceği sonucuna varılmıştır.

TEŞEKKÜR

Bu çalışma 1919B012221327 başvurusu numarası ile TÜBİTAK 2209-A üniversite öğrencileri araştırma projeleri destekleme programı kapsamında desteklenmiştir.

KAYNAKLAR

1. Çetinsaya, S. G. (2023). Türkiye'nin İnsansız Hava Araçları Serüveni. Anadolu Strateji Dergisi, 5(1), 1-27.
2. Koç, M. (2020). Derin öğrenme kullanarak İHA ile hareketli bir hedefin otonom olarak yakalanması (Master's thesis, İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Bilimleri ve Mühendisliği Anabilim Dalı).
3. Bayhan, E., Ozkan, Z., Namdar, M., and Basgumus, A. (2021). Deep learning based object detection and recognition of unmanned aerial vehicles. In 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 1-5.
4. Burgaz, M. (2020). Derin öğrenme algoritmaları kullanarak insansız hava araçları ile silah tespiti (Master's thesis, Batman Üniversitesi Fen Bilimleri Enstitüsü).
5. Voskuijl, M. (2022). Performance analysis and design of loitering munitions: A comprehensive technical survey of recent developments. Defence Technology, 18(3), 325-343.
6. Shahidi Zandi, M., and Rajabi, R. (2022). Deep learning based framework for Iranian license plate detection and recognition. Multimedia Tools and Applications, 81(11), 15841-15858.
7. Bayhan, E., Deligoz, C. B., Seymen, F., Namdar, M., and Basgumus, A. (2022). Unimpeded Walking with Deep Learning. In 2022 30th Signal Processing and Communications Applications Conference (SIU), pp. 1-4.

8. <https://suheadacilek.medium.com/resnet-residual-network-nedir-49105e642566> erişim tarihi: 01.10.2023
9. He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778.
10. Ozkan, Z., Bayhan, E., Namdar, M., and Basgumus, A. (2021). Object detection and recognition of unmanned aerial vehicles using Raspberry Pi platform. In 2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), pp. 467-472.
11. Namdar, M., Guney, A., Bardak, F. K., and Basgumus, A. (2023). Ergodic Capacity Estimation with Artificial Neural Networks in NOMA-Based Cognitive Radio Systems. Arabian Journal for Science and Engineering, 1-10.