



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



HASSAS GÜDÜMLÜ ATEŞLİ SİLAHLARIN
GRUP HALİNDE KULLANIMLARINDA
TAKTİKSEL ETKİNLİKLERİNİN
ARTIRILMASI

Rıdvan Safa HATİPOĞLU

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Ocak-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Rıdvan Safa HATİPOĞLU tarafından hazırlanan “Hassas Gdml Ateřli Silahların Grup Halinde Kullanımlarında Taktiksel Etkinliklerinin Artırılması” adlı tez alıřması 09/01/2025 tarihinde ařağıdaki jri tarafından oy birliğı / oy okluğı ile Konya Teknik niversitesi Lisansst Eğıtim Enstits Elektrik – Elektronik Mhendisliğı Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiřtir.

Jri yeleri

İmza

Başkan

Do. Dr. Kemal TTNC
Seluk niversitesi

.....

Danışman

Prof. Dr. Murat CEYLAN
Konya Teknik niversitesi

.....

ye

Prof. Dr. Bayram AKDEMİR
Konya Teknik niversitesi

.....

ye

Do. Dr. Hasan KOYUNCU
Konya Teknik niversitesi

.....

ye

Dr. Öğr. yesi Sabri ALTUNKAYA
Necmettin Erbakan niversitesi

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlt UYAN
Enstit Mdr

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Rıdvan Safa HATİPOĞLU

Tarih: 09/01/2025

ÖZET

DOKTORA TEZİ

HASSAS GÜDÜMLÜ ATEŞLİ SİLAHLARIN GRUP HALİNDE KULLANIMLARINDA TAKTİKSEL ETKİNLİKLERİNİN ARTIRILMASI

Rıdvan Safa HATİPOĞLU

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Murat CEYLAN

2025, 84 Sayfa

Jüri

**Prof. Dr. Murat CEYLAN
Prof. Dr. Bayram AKDEMİR
Doç. Dr. Hasan KOYUNCU
Doç. Dr. Kemal TÜTÜNCÜ
Dr. Öğr. Üyesi Sabri ALTUNKAYA**

Kızılötesi termal görüntüleme, nesnelerin yaydığı ısı enerjisinin algılanmasıyla oluşturulan bir görüntüleme yöntemidir. Görünür ışığa bağımlı olmaksızın hem gece hem de gündüz koşullarında etkili bir şekilde kullanılabilir. Bu özellik, özellikle görüşün kısıtlandığı çevresel koşullarda (sis, yağmur, kar vb.) önemli avantajlar sağlamaktadır. Çevresel faktörlerden etkilenme oranının düşük olması, termal görüntüleme sistemlerini askeri ve sivil alanlarda kritik durumlar için güvenilir bir çözüm haline getirmektedir. Askeri operasyonlarda, düşman unsurlarının yoğun sis, karanlık veya diğer olumsuz hava koşulları altında tespit edilmesi sahadaki operasyonel başarıyı artırmaktadır. Sivil alanlarda ise güvenlik taramaları, yangın tespiti ve arama kurtarma operasyonları gibi çeşitli uygulamalarda kullanılmaktadır. Termal görüntüleme teknolojisinin geniş kullanım potansiyeline rağmen, uç cihazlarda uygulanması sırasında karşılaşılan sınırlamalar, performans ve enerji verimliliğinin optimize edilmesini gerektirmektedir. Uç cihazlar, sınırlı işlem gücü, düşük enerji kapasitesi ve kompakt donanım yapıları nedeniyle, özellikle enerji verimli algoritmaların geliştirilmesi ve hafif yapay zeka modellerinin tasarımı gibi yenilikçi çözümlere ihtiyaç duymaktadır. Derin öğrenme tabanlı nesne tespiti modelleri, termal görüntüleme alanında doğruluk oranlarını artırmakta ancak yüksek hesaplama gereksinimleri nedeniyle uç cihazlarda performans ve enerji tüketimi arasında bir denge kurulmasını zorunlu kılmaktadır.

Tez çalışması, termal görüntüleme teknolojisinin uç cihazlarda nesne tespiti ve takibi için enerji verimli ve yüksek performanslı çözümler geliştirilmesine yönelik kapsamlı bir çerçeve sunmaktadır. Çalışmada, NVIDIA Jetson Nano, Xavier NX, Orin Nano, Orin NX ve Rockchip RK3588 gibi farklı uç cihaz platformlarının enerji tüketimi, işlem kapasitesi ve nesne tespiti performansları analiz edilmiştir. YOLOX, YOLOv8, YOLOv9, YOLOv10 ve Gold YOLO gibi yapay zeka tabanlı nesne tespiti modelleri bu uç cihazlarda çalıştırılarak termal görüntüler analiz edilmiştir. Modellerin doğruluk oranları, işlem hızları ve hesaplama maliyetleri karşılaştırılmıştır. Bu değerlendirme için RSH ve RSHAY parametreleri literatürde ilk kez bu tez çalışması ile tanımlanmış ve bu sayede hem uç donanım için en uygun yapay zeka modeli belirlenmiş hem de cihazlar arasında en verimli sistemin seçimi yapılmıştır. Gerçek zamanlı performansı artırmak amacıyla, obje tespit modellerinin yapısı optimize edilerek donanım hızlandırıcılar aktif şekilde kullanılmıştır. Jetson Orin Nano uç cihazında 512x512 piksel giriş çözünürlüğüne sahip YOLOv8 PostDas modelinin, termal görüntü analizinde en verimli uç donanım-obje tespit modeli çifti olduğu tespit edilmiştir. Çalışmanın bir diğer önemli katkısı, uç cihazların birbirleriyle koordinasyonunu sağlayan bir iletişim altyapısının geliştirilmesidir. Bu altyapı, uç cihazlarda tespit edilen nesnelerin ana sunucu bilgisayara aktarılmasını ve merkezi bir analiz süreci gerçekleştirilmesini içermektedir. Merkezi

analiz sayesinde cihazlar arası koordinasyon saęlanmıř ve nesne takibinde yenilikçi bir yaklařım ortaya konmuřtur. Sonuç olarak, termal görüntüleme sistemlerinin performansını artırırken enerji verimlilięini optimize eden tez çalışması, batarya ile çalışan taşınabilir gözetleme sistemlerinden insansız araçlara kadar geniş bir uygulama yelpazesi için ölçeklenebilir çözümler sunmuřtur.

Anahtar Kelimeler: Obje tespiti, Termal görüntüleme, Uç cihazlar, Uç cihaz haberleşmesi



ABSTRACT

PhD THESIS

INCREASING THE TACTICAL EFFECTIVENESS OF PRECISION-GUIDED FIREARMS IN GROUP USAGE

Rıdvan Safa HATİPOĞLU

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Prof. Dr. Murat CEYLAN

2025, 84 Pages

Jury

**Prof. Dr. Murat CEYLAN
Prof. Dr. Bayram AKDEMİR
Assoc. Dr. Hasan KOYUNCU
Assoc. Dr. Kemal TÜTÜNCÜ
Asst. Prof. Dr. Sabri ALTUNKAYA**

Infrared thermal imaging is a technique of visualization that captures the heat energy emitted by objects. Unlike systems dependent on visible light, thermal imaging works well in day and night conditions. This capability provides great advantages, especially under environmental constraints such as fog, rain, or snow. Due to its low susceptibility to environmental factors, thermal imaging systems are a reliable solution for critical applications in military and civilian domains. The ability to detect adversaries in heavy fog or in total darkness during military operations improves the outcome of a mission on the field. Thermographic cameras also find extensive use in civilian security screenings, fire detection, and search-and-rescue missions. Despite the wide potential of thermal imaging, its practical implementation on edge devices is fraught with challenges: there is a strong need to optimize performance and energy efficiency. With limited processing power, low energy capacity, and compact hardware, edge devices require innovative solutions, such as the development of energy-efficient algorithms and lightweight AI models. While deep learning-based object detection models improve the accuracy of thermal imaging considerably, they also involve a high degree of computational requirements, hence a delicate balance of performance and energy consumption arises on edge devices.

The main contribution of this thesis is the generic framework for developing energy-efficient and high-performance solutions to object detection and tracking problems in thermal imaging on edge devices. Energy consumption, processing capacity, and object detection performance of various edge device platforms such as the NVIDIA Jetson Nano, Xavier NX, Orin Nano, Orin NX, and Rockchip RK3588 are studied. These devices were utilized for the implementation of thermal image analysis using AI-based object detection models such as YOLOX, YOLOv8, YOLOv9, YOLOv10, and Gold YOLO. The accuracy rate, frame per second, and computational cost of the models have been compared. In this study, the newly introduced RSH and RSHAY in this thesis were applied for finding a suitable AI model that can work best for the edge hardware and for selecting the most efficient system across devices. To strengthen performance in real time, there was the optimization of object detection models, with hardware accelerators utilized actively. This model came out as the best combination of edge hardware and object detection model that was efficient in carrying out thermal image analysis with the YOLOv8 PostDas model on the Jetson Orin Nano edge device at an input resolution of 512x512 pixels.

The second crucial contribution provided by this paper is regarding the development of the communicating infrastructure that lets edge coordination happen. At the same time, this layer makes object detection propagate on this server for analysis purposes, wherein the contribution has gone for laying down

centralized coordination, altogether new approach and thus contributed toward object tracking with facility brought to coordination amidst several associated devices. Hence, facilitating centralized analysis gave room among various devices' coordination through object tracking between numerous devices being able to avail that resource.

The conclusions of this thesis contribute to the improvement of the performance of thermal imaging systems while optimizing energy efficiency. The results of the research will provide scalable solutions applicable in a wide range of systems, from battery-operated portable surveillance devices to unmanned vehicles, contributing both to academic research and industrial applications.

Keywords: Edge devices, Edge device communication, Object detection, Thermal imaging



ÖNSÖZ

Doktora tez çalışmalarım boyunca, değerli yardımları ve yönlendirmeleriyle bana yol gösteren, desteğini hiçbir zaman esirgemeyen danışmanım, Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Öğretim Üyesi Sayın Prof. Dr. Murat Ceylan'a en derin şükranlarımı sunarım.

Bu çalışmanın gerçekleşmesinde maddi ve manevi destekleriyle büyük katkı sağlayan Aselsan Konya Silah Sistemleri A.Ş.'nin yönetici ve Ar-Ge ekibine teşekkür ederim.

Son olarak, hayatımın her anında yanımda olan, destekleriyle beni güçlendiren değerli aileme, sevgisiyle bana cesaret ve ilham veren eşim Ayşe Hatipoğlu'na ve en büyük motivasyon kaynaklarımdan biri olan oğlum Aybars'a en içten minnet duygularıyla teşekkür etmeyi bir borç bilirim.

Rıdvan Safa HATİPOĞLU
KONYA-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Termal Görüntüleme Teknolojisinin Uygulama Alanları.....	4
2.2. Termal Görüntüleme Teknolojisi ve Nesne Tespitine Yönelik Araştırmalar.....	5
2.3. Uç Cihazlarda Termal Görüntüleme Teknolojisi ve Nesne Tespitine Yönelik Araştırmalar	8
3. MATERYAL VE YÖNTEM.....	10
3.1. Termal Veri Setleri	10
3.1.1. Teledyne FLIR veri seti	10
3.1.2. DSIAC termal veri seti	11
3.2. Obje Tespit Modelleri.....	14
3.2.1. YOLOX	19
3.2.2. Gold-YOLO	20
3.2.3. YOLOv8	21
3.2.4. YOLOv9	22
3.2.5. YOLOv10	23
3.2.6. Obje tespit modelleri değerlendirme kriterleri.....	25
3.3. Uç Cihazlar İçin Donanımlar	27
3.3.1. NVIDIA Jetson Nano.....	27
3.3.2. NVIDIA Jetson Xavier NX.....	28
3.3.3. NVIDIA Jetson Orin Nano	29
3.3.4. NVIDIA Jetson Orin NX	31
3.3.5. Rockchip RK3588.....	32
3.4. Uç Cihazların Performans Ölçümleri İçin Standartlar.....	33
3.5. Uç Cihazlar Arası Haberleşme	33
3.5.1. Gstreamer kütüphanesi	34
3.5.2. User Datagram Protocol (UDP) haberleşme.....	35
4. ARAŞTIRMA SONUÇLARI.....	36
4.1. Termal Veri Setinin Oluşturulması.....	36
4.1.1. Termal veriler ile gerçek dünya test ortamının hazırlanması	37
4.2. Obje Tespit Modellerinin Termal Veri Seti ile Eğitilmesi	39
4.3. Uç Cihazların Performans Ölçümleri	41

4.3.1. Obje tespit modelleri için son işlem aşamasının yapay zeka modeline entegrasyonu	44
4.3.2. Uygulama sonuçları	48
4.4. Uç Cihazlar Arası Haberleşme	69
5. SONUÇLAR VE ÖNERİLER	73
5.1 Sonuçlar	73
5.2 Öneriler	75
KAYNAKLAR	77



SİMGELER VE KISALTMALAR

Simgeler

AP_i	: Her i değeri için ortalama doğruluk değeri
α	: Giriş çözünürlüğünün normalize normalizasyonu
B	: Tahmin edilen sınır kutusu
C	: Koşullu sınıf olasılığı
C_1	: Sabit değerler
f	: Tüketilen güç başına üretilen FPS değerinin normalizasyonu
$G\check{C}x$	: Model giriş çözünürlüğü x değeri
$G\check{C}y$	: Model giriş çözünürlüğü y değeri
$M\check{C}x$	: Modelin en düşük giriş çözünürlüğü x değeri
$M\check{C}y$	: Modelin en düşük giriş çözünürlüğü y değeri
h	: Sınırlayıcı kutunun yükseklik değeri
M	: Milyon
m	: Genel ortalama hassasiyet değerinin normalizasyonu
m	: metre
mm	: milimetre
μ	: Görüntünün ortalama parlaklığı
$P(r)$	: Her doğruluk değerine karşılık gelen duyarlılık değeri
S	: Görüntünün bölündüğü ızgara sayısı
σ^2	: Görüntünün varyansı
σ_{xy}	: x ve y arası kovaryans
w	: Sınırlayıcı kutunun genişlik değeri
x	: Sınırlayıcı kutunun merkezinin x değeri
y	: Sınırlayıcı kutunun merkezinin y değeri

Kısaltmalar

3D	: Three-Dimensiona
ABD	: Amerika Birleşik Devletleri
AGT	: Advanced Ground Truth
AP	: Avarage Precision
ARF	: Advanced Recording Format
ARM	: Advanced RISC Machines
ATR	: Automatic Target Recognition
CIoU	: Complete IoU
CNN	: Convolutional Neural Network
CPU	: Central Process Unit
CSPNet	: Cross-Stage Partial Network
DAS	: Dual Assignment Strategy
DIoU	: Distance IoU
DN	: Doğru Negatif
DNN	: Deep Neural Network
DP	: Doğru Negatifdd
DSIAC	: Defense Systems Information Analysis Center
FEC	: Forward Error Correction

FPGA	: Field Programmable Gate Array
FPN	: Feature Pyramid Networks
GB	: Gigabayt
GELAN	: Generalized Label Assignment Network
GIoU	: Generalized Intersection over Union
GOH	: Genel Ortalama Hassasiyet
GPU	: Graphics Processing Unit
IoT	: Internet of Things
IoU	: Intersection over Union
İHA	: İnsansız Hava Aracı
LPDDR	: Low-Power Double Data Rate
MAE	: Masked AutoEncoder
mAP	: mean Average Precision
MP4	: MPEG-4
MWIR	: Mid-Wave Infrared
NMS	: Non-Maximum Suppression
NPU	: Neural Processing Unit
NVESD	: Night Vision and Electronic Sensors Directorate
ONNX	: Open Neural Network Exchange
PANet	: Path Aggregation Network
PGI	: Pyramid Gradient Integration
RAM	: Random Access Memory
RCNN	: Region Based Convolutional Neural Networks
RKNN	: Rockchip Neural Networks
RSH	: Ranking of Suitability for Hardware
RSHAY	: Ranking of Suitability for Hardware and Algorithmic Yield
RTP	: Real-time Transport Protocol
SimOTA	: Simplified Optimal Transport Assignment
SoC	: System on Chip
SPP	: Spatial Pyramid Pooling
SVM	: Support Vector Machine
TFLOPs	: Tera Floating Point Operations Per Second
TOPS	: Tera Operations Per Second
TPU	: Tensor Processing Unit
UDP	: User Datagram Protocol
YBİ	: Yapısal Benzerlik İnteksi
YN	: Yanlış Negatif
YOLO	: You Only Look Once
YP	: Yanlış Pozitif
KSA	: Konvolüsyonel Sinir Ağı

1. GİRİŞ

Kızılötesi termal görüntüleme, çevresel faktörlerden (sis, yağmur, kar vb.) en az etkilenen görüntüleme yöntemlerinden biri olarak farklı birçok alanda önemli bir kullanım potansiyeline sahiptir (Nguyen ve diğ., 2021). Termal görüntüleme, nesnelerin yaydığı kızılötesi ısı enerjisini algılayarak, görünür ışığa bağımlı olmadan gece ve gündüz koşullarında etkili bir şekilde çalışmaktadır (Ervural ve Ceylan, 2021). Bu sayede görüşün kısıtlı olduğu durumlarda büyük bir avantaj sağlayarak çeşitli alanlarında kolaylıkla kullanılmasına olanak tanımaktadır. Özellikle askeri uygulamalarda termal görüntüleme sistemleri, hedef tespiti, izleme, sınır güvenliği ve gece operasyonlarında yaygın olarak kullanılmaktadır (Bingöl ve diğ., 2012, Nguyen ve diğ., 2023). Düşman unsurlarını karanlıkta veya yoğun sis altında bile tespit etme yeteneği, askerlerin sahadaki etkinliğini arttırmaktadır (Wasaki ve diğ., 2001, Siegel, 2002, Kastek ve diğ., 2010). Sivil uygulamalarda ise termal görüntüleme, güvenlik sistemlerinden yangın tespitine kadar geniş bir yelpazede kullanılmaktadır. Özellikle bina içi veya açık alanlarda yapılan güvenlik taramalarında, şüpheli aktivitelerin ya da istenmeyen hareketlerin tespit edilmesinde önemli bir rol oynamaktadır (Wong ve diğ., 2009). Ayrıca, yangın tespit sistemleri, termal kameralar sayesinde duman ya da alev ortaya çıkmadan önce bile tehlikeleri algılayabilir, bu da erken müdahale imkânı sağlamaktadır (Arrue ve diğ., 2000, Paugam ve diğ., 2013). Endüstride, termal görüntüleme cihazları bakım ve arıza tespiti için vazgeçilmez bir araç haline gelmiştir. Elektrik panolarında aşırı ısınan parçaları tespit etme, boru hatlarındaki ısı kayıplarını gözlemleme ve makinelerde oluşabilecek arızaları önceden belirleme gibi uygulamalar, enerji tasarrufu ve operasyonel verimlilik sağlamaktadır (Rogler ve diğ., 1996, Jadin ve diğ., 2013). Ayrıca, hayvancılık, tarım, gıda ve inşaat sektörlerinde de kalite kontrol ve izleme süreçlerinde yaygın bir şekilde kullanılmaktadır (Dios ve diğ., 2006, Yanmaz ve diğ., 2007, Gowen ve diğ., 2010, Vadivambal ve diğ., 2011).

Termal görüntüleme sistemlerinin özellikle yapay zekâ ve derin öğrenme tabanlı modellerle entegrasyonu önem kazanmaktadır (Choi ve diğ., 2016, Rivadeneira ve diğ., 2019). Bu entegrasyon sayesinde, nesne tespiti ve takibi gibi karmaşık görevler termal görüntüler üzerinde daha etkili ve verimli bir şekilde gerçekleştirilebilmektedir (Batchuluun ve diğ., 2021). Derin öğrenme algoritmaları, termal görüntülerdeki karmaşık desenleri ve sıcaklık farklarını analiz ederek yüksek doğruluk oranları elde etmektedir. Özellikle konvolüsyonel sinir ağları (KSA) ve türevleri, termal görüntü işlemede yaygın

olarak kullanılmakta ve başarılı sonuçlar vermektedir. Ancak, bu çalışmaların çoğu, uç cihazların enerji verimliliği ve tespit doğruluğunu optimize etmek için sistematik bir yaklaşım içermemektedir (Farooq ve diğ., 2021, You ve diğ., 2022, Farooq ve diğ., 2023). Uç cihazlar, sınırlı işlem gücü ve enerji kaynakları nedeniyle, yüksek hesaplama gerektiren derin öğrenme modellerini çalıştırırken performans ve enerji tüketimi arasında bir denge kurmak zorundadır. Dolayısıyla, uç cihazlarda termal görüntüleme için hem enerji verimliliğini hem de tespit doğruluğunu optimize eden sistematik yaklaşımlara ihtiyaç vardır. Bu da model mimarilerinin optimize edilmesi, hafif derin öğrenme modellerinin geliştirilmesi, donanım hızlandırıcılarının etkin kullanımı ve enerji verimli algoritmaların tasarımı gibi çok disiplinli araştırma konularını içermektedir. Ayrıca, uç cihazlar arasında veri iletimini minimize eden ve gerçek zamanlı işlemeyi destekleyen iletişim protokollerinin geliştirilmesi de önemlidir. Böylece, termal görüntüleme sistemlerinin performansı artırılırken enerji tüketimi azaltılabilir ve pratik uygulamalarda daha geniş bir kullanım alanı sağlanabilir.

Bu tez çalışmasında, termal görüntüleme teknolojisi kullanarak uç cihazlarda nesne tespiti için kapsamlı bir çerçeve geliştirmesi hedeflenmiştir. Uç cihaz uygulamalarında karşılaşılan sınırlamalar, enerji verimliliği, işlem kapasitesi, gerçek zamanlı nesne tespiti ve veri iletişimi gibi konuların ele alınmasını gerektirmektedir. Bu bağlamda, tez çalışması hem akademik hem de uygulamalı araştırma ihtiyaçlarının karşılanmasını amaçlamıştır.

Çalışma kapsamında, NVIDIA Jetson Nano, Xavier NX, Orin Nano, Orin NX ve Rockchip RK3588 gibi uç cihazların performansları detaylı bir şekilde incelenmiştir. Her bir platformun nesne tespiti ve takip görevlerindeki işlem hızı, doğruluk oranı, enerji tüketimi ve gerçek zamanlı işlem kapasitesi gibi parametreler analiz edilmiştir. Bu analizler, uç cihazlarda ideal termal görüntüleme çözümlerinin belirlenmesinde kritik bir temel oluşturmaktadır. Bununla birlikte uç cihazlar üzerinde çalışacak yapay zeka temelli nesne tespiti için YOLOX, Gold-YOLO, YOLOv8, YOLOv9 ve YOLOv10 modellerinden yararlanılmıştır. Bu modellerin her biri, farklı optimizasyon teknikleri ve ağ mimarileri kullanarak nesne tespiti doğruluğunu ve hızını artırmayı hedeflemektedir. Çalışmada, bu modellerin termal görüntüler üzerinde nasıl performans gösterdiği karşılaştırılmış ve her bir modelin uç cihazlar üzerindeki performansı araştırılmıştır. Ayrıca modellerin obje tespiti için hesaplama maliyetleri ayrıntılı olarak incelenmiştir. Hesaplama işleminin kaynak kullanımlarının yeniden yapılandırılması ile modellerin gerçek zamanlı performansı artırılmış ve uç cihazın daha verimli çalışması sağlanmıştır.

Böylece hem donanım hem de yazılım düzeyinde optimal çözümler karşılaştırmalı olarak sunulmuştur.

Tez çalışması kapsamında, uç cihazların birlikte kullanıldığı senaryolarda grup etkinliğini sağlamak amacıyla tespit edilen nesnelerin paylaşılmasını mümkün kılan bir iletişim altyapısı geliştirilmiştir. Termal görüntüler içerisinde tespit edilen nesneler, görüntü içerisinden kırılarak ana uç cihazdan ana bilgisayara aktarılmaktadır. Ana bilgisayar, uç cihazlardan gelen tüm tespit edilmiş nesne verilerini işleyerek benzerlik analizi gerçekleştirmektedir. Bu analiz sonucunda, herhangi bir uç cihazın üzerinde işaretlenen nesne, diğer uç cihazlara iletilmektedir. Bu yöntem, sistemin merkezi bir analiz süreci sunmasını sağlarken, uç cihazlar arasında koordineli bir nesne işaretleme ve takip mekanizmasını mümkün kılmaktadır. Geliştirilen altyapı, cihazlar arası veri paylaşımını ve entegrasyonu optimize ederek, geniş ölçekli nesne takibini sağlayan verimli ve ölçeklenebilir bir çözüm sunmaktadır. Ayrıca bu yöntemle gerçek zamanlı analiz ihtiyaçlarına cevap verirken uç cihazlar arasında yüksek düzeyde koordinasyonu destekleyerek yenilikçi bir yaklaşım ortaya koymaktadır. Sonuç olarak, bu çalışma ile, termal görüntüleme teknolojisinin uç cihazlarda kullanımına yönelik yenilikçi bir çerçeve sunarak hem akademik literatüre hem de endüstriyel uygulamalara katkı sağlanması hedeflenmiştir. Çalışmanın sonuçları, batarya ile çalışan taşınabilir gözetleme sistemlerinden (kask kameraları, vücut kameraları, silah üstü elektro-optik sistemler vb.) insansız araçlara kadar birçok alanda uygulanabilir çözümler sunmaktadır.

2. KAYNAK ARAŞTIRMASI

Son yıllarda termal görüntüleme teknolojisindeki ilerlemeler, birçok alanda önemli yeniliklere olanak sağlamıştır. Bu yeniliklerin en dikkat çeken uygulama alanlarından biri de termal görüntülerdeki nesnelerin tespit edilmesidir. Termal görüntülerde nesne tespiti üzerine yapılan çalışmalar, önemli bir araştırma konusu olarak dikkat çekmekle beraber, uç cihaz performansları önemli bir zorluk barındırmaktadır.

2.1. Termal Görüntüleme Teknolojisinin Uygulama Alanları

Vollmer ve Möllmann (2010), kızılötesi termal görüntülemenin temel prensiplerini, araştırma alanlarını ve uygulamalarını detaylı bir şekilde ele almıştır. Bu inceleme, termal görüntülemenin bilimsel temellerini ve pratik uygulamalarını kapsamlı bir şekilde sunmaktadır. Akula ve ekibi (2011), termal görüntülemenin savunma sistemlerindeki uygulamalarını incelemiş ve bu teknolojinin askeri operasyonlardaki önemini değerlendirmiştir. Araştırmada, termal görüntülemenin savaş alanındaki farkındalığı artırmadaki rolü vurgulanmaktadır. Gade ve Moeslund (2013), termal kameraların çeşitli uygulamalarını incelemiş ve farklı sektörlerdeki kullanımı ile sağladığı avantajları analiz etmiştir. Yayında, termal kameraların güvenlik alanında yaygın olarak kullanıldığı ve doğruluk oranının %80'in üzerine çıktığı belirtilmiştir. Maurer ve diğ. (2013), askeri görüntüleme sistemlerinin arama ve tespit amaçlı kullanımlarını ele almıştır. Termal görüntüleme ile 2 metrekare boyutundaki hedeflerin 2 kilometre mesafeye kadar algılanabileceği belirtilmiştir. McEwan (2015), yüksek performanslı termal görüntülemenin askeri uygulamalarını incelemiş, bu teknolojinin savunma sektöründeki önemini ve potansiyel kullanım alanlarını değerlendirmiştir. Makalede, termal görüntülemenin keşif, gözetim ve hedef tespitindeki kritik rolü ortaya konulmuştur. Berg (2016), termal kızılötesi görüntülerde tespit ve izleme tekniklerini ele almış ve hareketli nesnelerin izlenmesinde termal görüntülemenin etkinliğini analiz etmiştir. Araştırma, özellikle güvenlik ve savunma alanlarında termal görüntülemenin hareketli hedeflerin izlenmesindeki rolünü vurgulamaktadır. Rai ve diğerleri (2017), termal görüntüleme sistemlerinin gerçek zamanlı uygulamalarını inceleyerek, bu teknolojinin çeşitli endüstriyel ve ticari alanlardaki kullanımını değerlendirmiştir. Termal görüntülemenin enerji denetiminden güvenlik sistemlerine kadar geniş bir uygulama yelpazesinde nasıl kullanıldığını göstermektedir. Narendran ve ekibi (2018), termal

görüntülemelerde nesne tespiti ve hedef parametrelerinin analizine dair bir derleme sunmuş ve bu alandaki mevcut teknikleri ile zorlukları ele almıştır. Yayında, termal görüntülemelerde nesne tespitinin doğruluğunu artırmak için kullanılan yöntemler ve bu yöntemlerin etkinliği tartışılmaktadır. Shimoni ve ekibi (2019), termal görüntülemenin askeri ve güvenlik uygulamalarındaki rolünü değerlendirerek, çeşitli işleme ve algılama tekniklerinin birleştirilmesinin hedef tespit ve tanımda nasıl iyileştirmeler sağladığını tartışmaktadır. Özellikle kamufle edilmiş veya gizlenmiş nesnelerin tespitinde sağladığı avantajları vurgulamaktadır. Peric ve diğ. (2019), termal görüntüleyicilerin menzil tahminlerini, beklentilerini ve gerçek performanslarını karşılaştırarak, bu sistemlerin operasyonel etkinliğini değerlendirmektedir. İncelemede, teorik tahminler ile saha verileri arasındaki farklar analiz edilerek termal görüntüleyicilerin gerçek dünya koşullarındaki performansı daha iyi anlaşılmaktadır. Tirupathamma ve diğ. (2020), kızılötesi termal görüntülemenin temel prensiplerini ve çeşitli uygulamalarını inceleyerek, bu teknolojinin farklı sektörlerdeki kullanım potansiyelini ortaya koymaktadır. Özellikle, termal görüntülemenin endüstriyel denetimden tıbbi teşhise kadar geniş bir yelpazede nasıl uygulandığına dair kapsamlı bir bakış sunulmaktadır. Nguyen ve diğ. (2023) çalışması, soğutmalı ve soğutmasız dedektörlerin yapısındaki değişikliklerin termal görüntüleme cihazlarının hassasiyetini artırdığını ve bu gelişmelerin askeri operasyonlarda nasıl uygulandığını detaylı bir şekilde incelemektedir. Araştırmada, termal görüntüleyicilerin silah sistemlerine entegrasyonunun, gece ve düşük görüş koşullarında bile etkinliği artırdığı gösterilmiştir.

2.2. Termal Görüntüleme Teknolojisi ve Nesne Tespitine Yönelik Araştırmalar

Termal görüntüler, nesne tespiti ve bilgisayarla görme alanında giderek artan bir öneme sahiptir. Bu alanda yapılan çeşitli araştırmalar, termal görüntülerin farklı uygulamalardaki rolünü ve derin öğrenme modellerinin etkinliğini incelemektedir. Ivasic-Kos ve diğ. (2019), YOLO algoritmasını kullanarak termal görüntülerde insan tespiti üzerine bir çalışma gerçekleştirmiştir. Araştırmada, görünür ışık ve termal veriler kullanılarak eğitilen YOLOv3 modelinin performansı karşılaştırılmıştır. Elde edilen sonuçlara göre, modelin termal görüntülerdeki doğruluk performansının görünür ışık verilerine kıyasla dört kat daha yüksek olduğu rapor edilmiştir. Cao ve diğ. (2019), termal görüntülerde nesne tespiti için geliştirilmiş tek aşamalı “ThermalDet” modeli önermiştir. Bu çalışma, R-CNN, MMTOD-UNIT, MMTOD-CG, RefineDet’den daha hızlı ve %74,6

GOH değeri ile daha doğru bir performans sunmuştur. Ippalapally ve diğ. (2020), termal görüntüleme kullanarak nesne tespiti üzerine bir çalışma gerçekleştirmiştir. Araştırma, özellikle düşük ışık koşullarında termal görüntülemenin üstünlüğünü vurgulamış ve derin öğrenme teknikleriyle entegrasyonun potansiyelini ortaya koymuştur. SSDMobileNet V1 ve SSDMobileNet V2 mimarileri kullanılan çalışmada FLIR veri seti kullanılmış ve SSDMobileNet V2'nin ortalama doğruluk ve ortalama duyarlılıkta daha iyi sonuç verdiği tespit edilmiştir. Krišto ve diğ. (2020), YOLO algoritmasını kullanarak zorlu hava koşullarında termal nesne tespiti üzerine bir çalışma gerçekleştirmiştir. Araştırmada, YOLOv3 modeli UNIRI-TID veri seti kullanılarak eğitilmiş ve farklı hava koşullarındaki performansı değerlendirilmiştir. Elde edilen ortalama doğruluk değerleri açık hava koşullarında %97,85, yağmur altında %98,08 ve sisli hava şartlarında %97,85 olarak rapor edilmiştir. Bu bulgular, termal görüntüleme teknolojisinin zorlu çevresel koşullarda nesne tespiti açısından yüksek bir başarı sağladığını ortaya koymaktadır. Murthy ve diğ. (2020), termal görüntülerle nesne tespiti için çeşitli derin öğrenme tekniklerini ve gömülü platformları kapsamlı bir şekilde incelemiştir. Araştırmada, YOLOv2, YOLOv3, SSD ve R-CNN mimarileri, Jetson TX1, TX2 ve Xavier AGX donanımları üzerinde test edilmiştir. Test sonuçlarına göre, YOLOv3 modeli doğruluk açısından diğer modellere üstünlük sağlarken, SSD modeli daha yüksek FPS üretme kapasitesiyle öne çıkmıştır. Juang ve diğ. (2020), dronlarla gerçekleştirilen devriye görevlerinde termal görüntüleme teknolojisinin kullanımını incelemiştir. Araştırmada, 416x416 piksel boyutunda termal görüntüler kaydedilmiş ve YOLOv3 ile YOLOv4 modelleri bu veri seti kullanılarak eğitilmiştir. Modellerin performansı, Nvidia Jetson TX2 donanımı üzerinde test edilmiş ve YOLOv4 modelinin doğruluk açısından YOLOv3 modeline kıyasla daha üstün bir performans sergilediği rapor edilmiştir. Patel ve diğ. (2020), termal ve görünür görüntüleri birleştirerek gece görüş izleme sistemleri için nesne tespiti gerçekleştirmiştir. Bu çalışma, çoklu spektral veri kullanmanın avantajlarını göstermiştir. Baek ve diğ. (2021), termal kızılötesi görüntü sensörleri kullanarak nesne tespiti üzerinde çalışmış ve bu teknolojinin özellikle güvenlik ve otomotiv uygulamalarında pratik faydalarını göstermiştir. Bu çalışma, gerçek zamanlı uygulamalarda yüksek doğruluk ve hızlı işlem kapasitesine vurgu yapmıştır. Sharrab ve diğ. (2021), EfficientDet, SSD MobileNet ve SSD ResNet tabanlı çeşitli derin öğrenme algoritmalarını termal görüntüler üzerinde karşılaştırmışlardır. Araştırma, bu modellerden EfficientDet ve SSD ResNet50 V1 modelinin diğer modellere göre daha iyi sonuçlar verdiğini belirtmiştir. Kera ve diğ. (2022), termal görüntülerde nesne tespiti için çok aşamalı blok tabanlı bir yaklaşım

geliştirmiştir. Tespit sürecini farklı aşamalara ayırarak işlem hızını artırmayı ve doğruluğu maksimize etmeyi amaçlayan bu çalışmada, FLIR veri seti kullanılarak 640x512 piksel çözünürlükte insan, bisiklet ve araç sınıflarında %77,3 Genel Ortala Hassasiyet (GOH, mAP) değeri elde edilmiştir. Sachan ve diğ. (2022), termal imzalara dayalı nesne tespitinde en yüksek doğruluk oranlarını sırasıyla ResNet50, CNN ve VGG16 modelleri kullanarak %91,94, %83,58 ve %81,23 olarak elde etmişlerdir. Eğitim sürecinde ise uyguladıkları “prefetch” ve “caching” yöntemleri ile 120,8 dakika süren eğitim süresini 90,6 dakikaya düşürmüş ve böylece enerji verimliliği açısından eğitim aşamasını iyileştirmişlerdir. Jiang ve diğ. (2022), İHA tabanlı termal görüntü ve videolardan nesne tespiti için YOLOv5-s modelini kullanmış ve %88,69 GOH değeri elde etmiştir. Araştırmada, tarımsal izleme ve vahşi yaşam gözlemi gibi alanlarda etkili sonuçlar elde edilmiştir. Skladchikov ve ekibi (2022), termal görüntüler üzerinde otomatik nesne tespiti için YOLOX derin öğrenme modelinin uygulanmasını incelemiştir. Yapılan çalışmada, YOLOX-m modeli için insan, bisiklet, araba ve köpek sınıflarında %55 GOH değeri elde edilmiştir. Bustos ve diğ. (2023), yakın kızılötesi ve termal görüntüler kullanılarak yapılan nesne tespiti üzerine sistematik bir literatür incelemesi gerçekleştirmiştir. İnceleme, termal veriler kullanılarak nesne tespitindeki son gelişmeleri belgelemekte ve multispektral tekniklerin olumsuz koşullarda daha iyi performans gösterdiğini vurgulamaktadır. Kamaleswari ve Krishnaraj (2023), termal görüntü işlemeyle nesne tespitine dair ayrıntılı bir analiz sunmuştur. İncelemede, termal görüntülerde nesne tespitinin etkinliği değerlendirilmiştir ve YOLOv7 mimarisinin daha önceki mimarilere göre %40 daha verimli çalıştığı belirtilmiştir. Soeleman ve diğ. (2023), insansız hava araçlarıyla termal görüntüler üzerinde nesne tespiti için derin öğrenme modelleri geliştirmiştir. Çalışmada, YOLOv5 yapısının temel alındığı ve "transformer encoder" ile desteklenen bir model tasarlanmıştır. Model, VEDAI veri setlerinde ResNet, Faster RCNN ve YOLOv5 gibi yöntemlerden 800x800 piksel çözünürlükte %89,76 GOH ile daha yüksek doğruluk sergilemiştir. Gallagher ve Oughton (2023), hava tabanlı platformlarda nesne tespiti yöntemlerine termal görüntü entegrasyonunu değerlendirmiştir. Araştırmada, termal görüntülerin hava tabanlı nesne tespitindeki etkisi analiz edilmiştir ve YOLOv8 modelinin %85,3 GOH değerine ulaştığı belirtilmiştir. Pandurangan ve Nagappan (2024), termal görüntülerin kullanıldığı geniş bir uygulama yelpazesinde nesne tespitine yönelik kapsamlı bir araştırma sunmuşlardır. Araştırmada, YOLO gibi modern nesne tespit algoritmalarının termal görüntüler üzerindeki performansı analiz edilmiştir. Analiz sonucunda, YOLOv8 modelinin termal

görüntülerde 150 epok sonrasında %87,4 genel ortalama hassasiyet değerine ulaştığı belirtilmiştir.

2.3. Uç Cihazlarda Termal Görüntüleme Teknolojisi ve Nesne Tespitine Yönelik Araştırmalar

Uç cihazlarda termal obje tespiti, gerçek zamanlı ve enerji verimli çözümler sunan, özellikle sınırlı işlem gücüne sahip sistemlerde önemli bir araştırma alanıdır. Termal görüntüler, zorlu çevre koşullarında görünürlüğü artırmakta ve bu tür cihazların otomotiv, güvenlik, artırılmış gerçeklik ve enerji yönetimi gibi geniş bir uygulama yelpazesinde etkili olmasını sağlamaktadır. Araştırmalar, uç cihazlardaki termal obje tespitine yönelik algoritmaların geliştirilmesi, optimizasyonu ve uygulanabilirliğine odaklanmaktadır. Termal görüntüleme ve uç cihazlarda nesne tespiti üzerine yapılan çalışmalar, enerji verimliliğini artırarak gerçek zamanlı uygulamalarda yüksek doğruluk sağlamayı hedeflemiştir. Farooq ve diğ. (2021), ileri sürücü destek sistemlerinde termal görüntüler kullanarak nesne tespiti gerçekleştirmiştir. YOLOv5-s mimarisinin kullanıldığı çalışmada, 7 farklı sınıf için eğitilen modelde %85,8 GOH elde edilmiştir. Nvidia Jetson Nano üzerinde test edilen modelin, donanım optimizasyonu sonrasında saniyede üç kare üretebildiği rapor edilmiştir. Farooq ve diğ. (2022), termal görüntüleme ile elde edilen verileri gömülü GPU platformlarında değerlendirerek nesne tespiti üzerine bir çalışma gerçekleştirmiştir. Araştırmada, YOLOv5 mimarisi termal görüntülerle eğitilmiş ve %71,8 GOH değeri elde edilmiştir. Modeller, farklı gömülü GPU platformlarında test edilmiştir; Jetson Xavier NX üzerinde modelin saniyede 60 kare (Frame per Second, FPS) ile nesne tespiti yapabildiği, Jetson Nano platformunda ise bu hızın 11 FPS olarak gerçekleştiği rapor edilmiştir. Yuan ve Agaian (2022), BiThermalNet isimli hafif bir ağ geliştirerek savunma uygulamalarında enerji verimliliği ve doğruluk sağlamıştır. Çalışmada modelin hem düşük enerji tüketimi hem de yüksek tespit doğruluğu sunduğu belirtilmiştir. Farooq ve diğ. (2023), ileri görüş sistemlerinin geliştirilmesi ve uç cihazlarda optimizasyonu üzerine çalışmalar yaparak, bu sistemlerin otonom araçlarda güvenliği artırdığını göstermiştir. Araştırmada, Tiny YOLO-v5 olarak adlandırılan bir model geliştirilmiş ve C3I Termal Otomotiv veri seti üzerinde %56,4 GOH elde edilmiştir. Model, Raspberry Pi 4 platformunda 128x128 piksel çözünürlükte test edilmiş ve 2,5 FPS performansına ulaşmıştır. Li ve Ye (2023), kızılötesi nesne tespiti için enerji verimli bir yöntem sunmak amacıyla Edge-YOLO adını verdikleri hafif bir

model geliřtirmiřtir. YOLOv5 modelinin deęiřtirilmesiyle oluřturulan bu modelde, %78,8 GOH deęeri elde edilmiř ve bu doęruluk oranıyla YOLOv5-m modeline eřdeęer bir performans sergilemiřtir. Bununla birlikte, Edge-YOLO modelinde önemli iyileřtirmeler yapılmıřtır: parametre sayısında %72,2, hesaplama maliyetinde %70,3 ve model boyutunda %71,6 oranında dūřuř saęlanmıřtır. Bu optimizasyonlar sayesinde RK3588 uę cihazında 31,9 FPS ile geręek zamanlı performans elde edilmiřtir. Sonuęlar, uę cihazların sınırlı donanım kapasitelerinde dahi etkin bir řekilde kullanılabileceęini gōstermiřtir. Hatipoęlu ve Ceylan (2024), batarya ile ęalıřan RK3588 uę cihazının termal gōrüntüleme ile geręek zamanlı ęalıřma performansını incelemiřlerdir. Arařtırma, 512x512 piksel ęözünürlük deęerleri ięin hem YOLOX hem de YOLOv8 modellerinin geręek zamanlı ęalıřabildięini ortaya koymuřtur. Hatipoęlu ve Ceylan (2024), Jetson Xavier NX uę cihazında YOLOv9 modelini termal gōrüntüler ile eęitmiř ve GPU hızlandırıcılarını kullanarak modelin performansını artırmıřlardır. Bu hızlandırma yöntemi sayesinde, 640x640 piksel ęözünürlükte 15 FPS deęeri ile geręek zamanlı ęalıřamayan model, 27 FPS ile geręek zamanlı ęalıřabilir hale getirilmiřtir.

3. MATERYAL VE YÖNTEM

Tez çalışmasında, termal görüntüleme teknolojisi kullanılarak nesne tespiti ve takibi yeteneğine sahip, birbiri ile haberleşebilen bir sistemin geliştirilmesi üzerine odaklanılmıştır. Bu kapsamda, uç cihazlar cihazların gerçek zamanlı işlem kapasiteleri ile birlikte güç tüketim performansları incelenmiş, performans ve verimliliği artırmaya yönelik yöntemler geliştirilmiştir. Bununla birlikte grup halinde kullanımlarda etkinliğin artırılmasını sağlayan haberleşme ağı kurulmuştur.

Bu bölümde, termal veri setleri, yapay zekâ tabanlı obje tespit modelleri ve uç cihazların performansını ölçmek için tasarlanan sistemin ayrıntıları verilmiştir. Ayrıca, uç cihazlar arasında gerçek zamanlı haberleşme ve veri paylaşımı sağlamak için geliştirilen yöntem açıklanmaktadır.


3.1. Termal Veri Setleri

Tez çalışmasında, nesne tespiti termal görüntüler üzerinde gerçekleştirilmiştir. Termal görüntüler, FLIR Termal veri seti (FLIR Systems, 2018) ve DSIAC veri Seti (DSIAC, 2010) kullanılarak elde edilmiştir. Her iki veri seti de termal görüntüleme uygulamalarında nesne tespiti modellerinin değerlendirilmesi için uygun özelliklere sahiptir. Obje tespit modellerinin termal görüntüler ile eğitilmesi için FLIR Termal veri seti özelleştirilmiştir. DSIAC veri seti, gerçek dünya sahnelerini simüle etmek amacıyla, eğitim veri setine dahil edilmeden, uç cihaz ve obje tespit modeli karşılaştırma parametrelerinin hesaplanması için bu çalışma kapsamında kullanılmıştır.

3.1.1. Teledyne FLIR veri seti

FLIR Termal Veri Seti (FLIR Systems, 2018), yüksek çözünürlüklü kızılötesi termal görüntülerden oluşmaktadır. Bu veri seti, nesne tespiti görevleri için özel olarak hazırlanmış olup, gündüz ve gece senaryoları, farklı hava koşulları ve çeşitli nesne kategorilerini içermekle birlikte güvenlik, gözetim ve otonom sürüş gibi uygulamalar için önemli bir kaynak teşkil etmektedir. Görüntülerin kaydedildiği termal kamera 640x512 piksel çözünürlüğe sahip, 13 mm f/1.0 lensi bulunan Teledyne FLIR Tau 2 modelidir. Görünüş ışık kamerası ise Teledyne FLIR Blackfly S BFS-U3-51S5C (IMX250) kameradır. Veri seti içerisinde 15 farklı sınıf (insan, bisiklet, araba, motosiklet, otobüs,

tren, kamyon trafik ışığı, yangın hidrantı, sokak tabelası, köpek, kaykay, bebek arabası, mobilet, diğer araçlar) bulunmaktadır ve 520000 etiketlenmiş sınırlayıcı çerçeve içermektedir (Şekil 3.1). Eğitim ve doğrulama için 9.711 termal görüntü ve 9.233 görünür ışık görüntüsü bulunmaktadır.



Şekil 3.1. Teledyne FLIR termal veri seti (Davies, 2022)

3.1.2. DSIAC termal veri seti

DSIAC veri seti, ATR (Automatic Target Recognition) algoritmalarının geliştirilmesi amacıyla ABD Ordusu Gece Görüş ve Elektronik Sensörler Müdürlüğü (NVESD) tarafından oluşturulmuştur. Veri seti, 512x640 piksel çözünürlüğünde geniş bir MWIR (Mid-Wave Infrared) ve görünür ışık görüntü koleksiyonu içermektedir (DSIAC, 2010). Bu veri seti, farklı çevresel koşullarda ve hedef türlerinde çekilmiş görüntüleri barındırarak derin öğrenme tabanlı algoritmaların değerlendirilmesi için zengin bir kaynak sunmaktadır.

Veri setinde insan hedefleri için şu görüntü paketleri bulunmaktadır:

- 17 adet gündüz kaydedilen görünür ışık görüntü paketi,
- 18 adet gündüz kaydedilen MWIR görüntü paketi,
- 12 adet gece kaydedilen MWIR görüntü paketi.

Araç hedefleri için ise şu görüntü paketleri yer almaktadır:

- 80 adet gündüz kaydedilen görünür ışık görüntü paketi,
- 82 adet gündüz kaydedilen MWIR görüntü paketi,
- 76 adet gece kaydedilen MWIR görüntü paketi.

DSIAC görüntüleri, Advanced Recording Format (ARF) dosya uzantısında videolar olarak saklanmaktadır. Buna ek olarak, her video dosyasıyla birlikte hedeflerin konumu, sayısı, mesafesi gibi bilgileri içeren geniş bir temel gerçeklik (ground truth) verisi, Advanced Ground Truth (AGT) formatında depolanmıştır. Bu zengin veri yapısı, algoritmaların hassasiyetini ve doğruluğunu artırmaya yönelik kapsamlı bir test altyapısı sağlamaktadır.

Veri setindeki ARF ve AGT formatındaki dosyaların adlandırılması, hedef hakkında bilgi içeren akıllı bir numaralandırma sistemi ile yapılmıştır. Dosya isimleri (hhhh)(nnnn)-(nnnn).ARF/AGT biçiminde saklanmaktadır. Burada, “hhhh” kısmı görüntünün MWIR veya görünür ışık formatında olduğunu ifade etmektedir. (Çizelge 3.1). Bu numaralandırma yapısı, dosyaların içeriğine hızlı bir şekilde erişim sağlamak için optimize edilmiş ve veri setinin kullanımını kolaylaştırmaktadır.

Çizelge 3.1. Veri seti isim formatı

Format	Sensör Tipi
cegr	MWIR
ilco	Görünür ışık

Veri setindeki dosya isimlendirmelerinde, orta kısımda yer alan “nnnn” bölümü senaryo numarasını temsil etmektedir. Bu senaryo numaraları, görüntülerin gece veya gündüz kaydedildiğini, verilerin insan ya da araç hedeflerine ait olduğunu ve hedefin mesafesini belirtmektedir (Çizelge 3.2 ve Çizelge 3.3).

Çizelge 3.2. Araç hedeflerinin veri seti isim formatı

Gündüz	Gece	Mesafe (m)
2003	1923	1000
2005	1925	1500
2007	1927	2000
2009	1929	2500
2011	1931	3000
2013	1933	3500
2015	1935	4000
2017	1937	4500
2019	1939	5000

Çizelge 3.3. İnsan hedeflerinin veri seti isim formatı

Gündüz	Gece	Mesafe (m)
2002	1926	500
2004	1928	1000
2006	1932	1500
2008	1934	2000
2010	1936	2500
2012	1938	3000

Dosya isimlendirmelerinin son kısmında yer alan “nnnn” bölümü ise hedef hakkında daha ayrıntılı bilgileri ifade etmektedir (Çizelge 3.4 ve Çizelge 3.5).

Çizelge 3.4. Araç hedeflerinin isimlendirmeleri

Numara (nnnn)	Hedef Tipi
0001	Pickup
0002	Hizmet Aracı
0005	BTR70 – Armored Personel Carrier
0006	BRDM2 – Infantry Scout Vehicle
0009	BMP2 – Armored Personel Carrier
0010	T62 – Main Battle Tank (broke down early, rarely used)
0011	T72 – Main Battle Tank
0012	ZSU23-4- Anti-Aircraft Weapon
0013	2S3 – Self-Propelled Howitzer
0014	MTLB – Armored Reconnaissance Vehicle Towing a D20 Artillery Piece

Çizelge 3.5. İnsan hedeflerinin isimlendirmeleri

Numara (nnnn)	Hedef Tipi
0001	Yavaş hızda hareket eden insanlar
0002	Hızlı hareket eden insanlar

Bu bilgiler, her bir kaydın içeriğiyle ilgili detaylı meta veriler sunarak analiz süreçlerini kolaylaştırmaktadır. Örneğin, veri setinde yer alan “cegr01929_0006.arf” isimli dosya, gece şartlarında MWIR sensörü ile BRDM2 aracına ait, 2500 metre mesafeden kaydedilmiş görüntülerden oluşan bir videoyu ifade etmektedir. Diğer bir örnek olan “ilco02006_0002.arf” dosyası ise, görünür ışık sensörü ile hızlı hareket eden insanların 1500 metre mesafeden kaydedilmiş videolarını içermektedir. Veri seti içerisinde yer alan araç hedeflerinin örnek görüntüleri Şekil 3.2’de verilmiştir. Ancak, insan hedeflerine ait yakın çekim görseller veri setinde bulunmamaktadır. Veri setinin sistematik yapısı askeri-sivil uygulamalarda kullanılacak otomatik hedef tanıma algoritmalarının geliştirilmesini desteklemektedir.




Şekil 3.2. Araç hedeflerinin görselleri

3.2. Obje Tespit Modelleri

Bu çalışmada, termal görüntüler üzerinde nesne tespiti için derin öğrenme tabanlı tek aşamalı modellerin performansları değerlendirilmiştir. İncelenen modeller arasında YOLOX, Gold-YOLO, YOLOv8, YOLOv9 ve YOLOv10 bulunmaktadır.

You Only Look Once (YOLO), 2015 yılında yayınlanmış olup, ilk derin öğrenme tabanlı tek aşamalı nesne dedektörü olarak literatüre geçmiştir (Redmon ve diğ., 2016). YOLO, nesne tespitini bir regresyon problemi olarak ele alır ve sınır kutusu koordinatlarını (bounding box) ile sınıf olasılıklarını tek bir geçişte tahmin eder. Bu yaklaşımıyla, diğer çok aşamalı tespit yöntemlerinden farklı olarak daha hızlı ve etkili bir nesne tespit süreci sunar.

YOLO obje tespit modelleri Omurga (Backbone), Boyun (Neck), Kafa (Head), Kayıp Fonksiyonları (Loss Functions), Son İşlem Katmanı (Post Processing) olmak üzere beş ana katmandan oluşmaktadır. Bu katmanlar içinde kullanılan algoritmaların yapısına göre modelin başarımlı oranı, hızı ve parametre sayısı değişmektedir. Şekil 3.3'de YOLO mimarisinin görselleştirilmiş hali görülmektedir.



Şekil 3.3. YOLO mimarisi (Scius-Bertrand ve diğ., 2021)

YOLO mimarisinin ana katmanlarından olan omurga, modelin ana özellik çıkarma (feature extraction) kısmıdır. YOLO'un omurgası genellikle bir derin konvolüsyonel sinir ağı (KSA, CNN) mimarisinden oluşur ve girdiden anlamlı özelliklerin çıkarılmasından sorumludur. Bu özellikler, görüntüdeki kenarlar, dokular ve nesne sınırları gibi temel görsel öğelerden oluşur ve modelin sonraki bölümleri tarafından işlenmek üzere hazırlanır (Redmon ve Farhadi, 2018; Bochkovskiy ve diğ., 2020). Ayrıca, farklı çözünürlüklerde birden fazla özellik haritası üretilir. Bu, modelin farklı boyutlardaki nesneleri algılamasına olanak sağlar ve özellikle nesne tespiti sırasında önemli bir avantaj sunmaktadır (Lin ve diğ., 2017; Wang ve diğ., 2021). Omurganın diğer bir özelliği ise görüntüyü daha küçük boyutlara indirerek (down-sampling) daha kompakt bir veri temsili oluşturmasıdır. Bu veri temsili, modelin girdiyi daha hızlı işlemesine olanak tanır ve işlem yükünü azaltır (He ve diğ., 2016). Aynı zamanda modelin en yoğun hesaplama yükünü üstlenir ve diğer bölümlere aktarılabilecek olan özellik haritalarını oluşturur. Bu sebeple modelin genel performansı açısından önemlidir (Howard ve diğ., 2017). Son olarak, omurga, modelin diğer bölümleri olan Boyun ve Kafa için genel amaçlı özellikler sağlar. Bu özellikler, modelin temel verilerini oluşturmaktadır (Liu ve diğ., 2018).

YOLO mimarisinde diğer ana bileşenlerinden biri olan boyun bileşeni, omurgadan alınan özellik haritalarını baş kısmına ileten ve modelin nesne algılama performansını artırmada kritik rol oynayan bir ara katmandır. Bu bileşen, farklı ölçeklerdeki nesnelerin algılanabilirliğini iyileştirmek amacıyla özelliklerin birleştirilmesini ve optimize edilmesini sağlar. Boyun, yüksek ve düşük çözünürlüklü özellik haritalarını entegre ederek küçük ve büyük nesnelerin aynı doğrulukla algılanmasını kolaylaştırır (Lin ve diğ., 2017). Omurgadan gelen düşük ve yüksek çözünürlüklü özellik haritalarının birleşimi sırasında, gereksiz bilgiler filtrelenir ve önemli olanlar vurgulanır. Bu süreç, modelin sınırlayıcı kutularını daha doğru yerleştirmesine ve nesneleri daha etkili bir şekilde sınıflandırmasına olanak tanır. Örneğin, Feature Pyramid Networks (FPN), düşük çözünürlüklü özellikleri yukarı örnekleyerek yüksek çözünürlüklü özelliklerle birleştiren temel bir yapıdır. Bu yöntem, bilgi kaybını en aza indirerek model doğruluğunu artırır (Lin ve diğ., 2017). Daha gelişmiş bir yapı olan Path Aggregation Network (PANet) ise bilgi akışını çift yönlü olarak düzenler ve yukarı ve aşağı örnekleme süreçlerini bir arada gerçekleştirir. PANet, bilgi akışını optimize ederek modelin performansını artırır (Liu ve diğ., 2018). Modern


YOLO modelleri, boyun kısmında gelişmiş yöntemler kullanarak performansı daha da artırmaktadır. Örneğin, YOLOv8 ve YOLOv9 modellerinde kullanılan Spatial Pyramid Pooling (SPP) ve geliştirilmiş PANet yapıları, farklı çözünürlüklerdeki özellik haritalarını daha verimli bir şekilde birleştirmektedir. Bu yaklaşımlar, modelin hem doğruluğunu hem de işlem hızını artırarak gerçek zamanlı nesne algılama uygulamaları için uygun hale getirir (Bochkovskiy ve diğ., 2020; Wang ve diğ., 2023).

YOLO mimarisindeki kafa bileşeni, omurgadan ve boyundan gelen özellik haritalarını işleyerek nesne tespiti ve sınıflandırma görevlerini gerçekleştiren bir yapıdır. Bu bileşen, belirli bir girdiye karşılık gelen nesnelerin sınıf etiketlerini, konumlarını ve çerçevelerini (bounding boxes) belirler. Kafa, modelin temel çıktısını oluşturduğu için nesne tespit performansını doğrudan etkiler (Redmon ve diğ., 2016). YOLO mimarisinde kullanılan kafa yapıları, modelin gerçek zamanlı nesne tespiti performansını artırmak için optimize edilmiştir. Örneğin, YOLOv3 ve YOLOv4 modellerinde kullanılan çapa-tabanlı (anchor-based) kafa yapıları, farklı ölçeklerde önceden tanımlanmış çapa kutularını kullanarak nesnelerin sınıflandırma ve konumlandırma doğruluğunu artırır (Bochkovskiy ve diğ., 2020). Ancak bu yöntem, hesaplama maliyetini artırabileceği için daha yeni modellerde çapa-serbest (anchor-free) yapılar tercih edilmeye başlanmıştır. Modern YOLO modelleri, çapa-serbest kafa yapıları ile daha düşük hesaplama maliyetine ve daha yüksek doğruluğa ulaşmıştır. Örneğin, YOLOX modelinde kullanılan çapa-serbest yapı, doğrudan nesnelerin merkez noktalarını ve boyutlarını tahmin ederek hem işlem hızını artırır hem de daha esnek bir yapı sunar (Ge ve diğ., 2021). Benzer şekilde, YOLOv8 ve YOLOv9'da kullanılan adaptif baş yapıları, nesne tespiti görevlerini daha verimli bir şekilde yerine getirebilmek için giriş verilerine göre dinamik olarak uyarlanır (Jocher ve diğ., 2023).

Kafa bileşenlerinde kullanılan kayıp fonksiyonları (loss functions), modelin doğruluğunu ve optimizasyon sürecini doğrudan etkiler. Kayıp fonksiyonları (loss functions), nesne tespiti modellerinin eğitimi sırasında tahmin edilen çıktılar ile gerçek değerler arasındaki farkı hesaplayan ve modelin optimizasyon sürecini yönlendiren kritik bileşenlerdir. YOLO mimarisinde, kayıp fonksiyonları üç ana hedef üzerinde çalışır: sınıflandırma doğruluğu, çerçeve tahmini (bounding box regression) ve nesne varlık skoru (objectness score). Her bir hedef, farklı kayıp fonksiyonları ile optimize edilir (Redmon ve diğ., 2016). Örneğin, YOLOv4 ve sonrasında Generalized Intersection over Union (GIoU) kaybı, tahmin edilen çerçevelerin gerçek çerçevelere uyumunu artırmak için kullanılan bir fonksiyondur. Bu fonksiyon, yalnızca çerçevelerin örtüşme oranını

değil, aynı zamanda çerçeve konumlarının uzaysal dağılımını da dikkate alır (Zheng ve diğ., 2020). YOLOv8 gibi daha yeni modellerde ise Complete IoU (CIoU) ve Distance IoU (DIOU) kayıp fonksiyonları, çerçeve tahminlerinde daha hassas optimizasyonlar sağlayarak model performansını artırır (Jocher ve diğ., 2023). Ayrıca modern YOLO modelleri, bu kayıp fonksiyonlarını birleştirerek daha karmaşık ve dengeli bir öğrenme süreci sağlar. Örneğin, YOLOv9 ve YOLOv10 modellerinde kullanılan birleşik kayıp fonksiyonları (Unified Loss), sınıflandırma, çerçeve tahmini ve nesne varlık skorunu aynı anda optimize ederek modelin genel doğruluğunu artırır (Ge ve diğ., 2021).

Son işlem katmanı (post-processing), modelin çıktılarını işleyerek son kullanıcıya anlamlı bilgiler sunar. Bu aşama, genellikle tahmin edilen çerçeveleri sıralama, düşük güven skorlu tahminleri eleme ve tekrarlayan çerçeveleri kaldırma gibi işlemleri içerir. YOLO modellerinde, Non-Maximum Suppression (NMS) ve geliştirilmiş versiyonları, bu işlemler için yaygın olarak kullanılan algoritmalarlardır. NMS, aynı nesne için birden fazla tahmin edilen çerçeve olması durumunda en yüksek güven skorlu çerçeveyi seçer ve diğerlerini eler (Neubeck ve Gool, 2006). Daha yeni modellerde, Soft-NMS ve Weighted-NMS gibi yöntemler, klasik NMS'in sert eşikleme mekanizmasını yumuşatarak daha hassas sonuçlar elde edilmesini sağlar (Bodla ve diğ., 2017). Örneğin, YOLOv8 ve YOLOX modellerinde bu yöntemler, özellikle yoğun nesne tespiti yapılan senaryolarda tahmin doğruluğunu artırmıştır (Ge ve diğ., 2021; Jocher ve diğ., 2023). YOLO obje tespit modellerinin girişine bir görüntü sağlanması durumunda, giriş görüntüsü $S \times S$ boyutunda bir ızgaraya bölünür. Bu ızgaranın her bir hücresi, merkezi bu hücrenin içinde yer alan nesneleri tespit etmekten sorumludur. Şekil 3.4'de gösterildiği gibi, her hücre; merkez koordinatları, genişlik, yükseklik ve bir güven skoru içeren B adet sınır kutusunu ve C adet koşullu sınıf olasılığını tahmin eder. Bu tahminler, belirli bir giriş görüntüsü için $S \times S \times (B \times 5 + C)$ boyutunda bir tensörle ifade edilebilir (Aksoy, 2022).



Şekil 3.4. YOLO mimarisinin son işlem katmanı önce ve sonrası (Aksoy, 2022).

Ancak, tahmin edilen sınır kutuların tamamı, görüntüdeki gerçek nesnelerle eşleşmeyebilir. Bu nedenle, gereksiz ve zayıf tahminlerden kurtulmak için tahminlerin filtrelenmesi gerekir. İlk aşamada, güven skoru belirli bir eşik değerin altında olan tahmin edilen sınır kutuları elenir. Bu işlem, zayıf veya alakasız tahminlerin elenmesini sağlar. Ancak, bu eleme sürecinin ardından bile aynı nesneye ait birden fazla yüksek güven skorlu sınır kutusu mevcut olabilir. Bu tür durumlarda, YOLO, gereksiz sınır kutularını ortadan kaldırmak için Maksimum Olmayan Bastırma (Non-Maximum Suppression, NMS) yöntemini kullanır. NMS, aynı nesneyi temsil eden kutular arasında en yüksek güven skorlu kutuyu seçer ve diğer kutuları belirli bir IoU (Intersection over Union) eşliğine göre bastırır (Şekil 3.5). IoU, iki sınır kutusunun örtüşme oranını ölçerek, gereksiz tahminlerin elimine edilmesine yardımcı olur. YOLO'nun bu yapısı, tespit işlemini hızlı ve verimli bir şekilde gerçekleştirirken, aynı zamanda çoklu nesne tespitinde doğruluğunu artırır. Tek geçişli mimarisi, özellikle gerçek zamanlı uygulamalarda, yüksek performans gerektiren sahnelerde ve sınırlı donanım kaynaklarında ideal bir çözüm sunar. YOLO'nun yenilikçi yaklaşımı, nesne tespitinde kullanılan birçok yöntemin temelini oluşturmuş ve sonraki versiyonlarına yol açmıştır.



Şekil 3.5. NMS algoritması aşamaları (Wang ve diğ., 2019)

3.2.1. YOLOX

YOLOX modeli, Ge ve ekibi (2021) tarafından duyurulmuş olup, YOLO dedektörüne bir dizi iyileştirme getiren modern bir nesne tespit modeli olarak literatüre katkı sağlamıştır. Yazarlar, temel model olarak Darknet53 omurgasına sahip YOLOv3'ü tercih etmişlerdir. YOLOX, mimari tasarımında yapılan çeşitli yeniliklerle hem hassasiyeti hem de yakınsama hızını artırmayı hedeflemiştir.

YOLOX'in getirdiği ilk yenilik, sınıflandırma ve regresyon görevlerini bağımsız olarak yürütmek amacıyla algılama kafasını "ayrılmış kafa" (decoupled head) mimarisiyle değiştirmesidir. Bu strateji, sınıflandırma ve regresyon görevleri arasındaki potansiyel çatışmayı çözerek her iki görevin daha verimli bir şekilde öğrenilmesine olanak tanır. Bu yaklaşım, modelin doğruluğunu artırmanın yanı sıra yakınsama hızını da önemli ölçüde iyileştirmiştir (Song ve diğ., 2020, Wu ve diğ., 2020).

İkinci büyük yenilik ise çapasız (anchor-free) bir tasarımın benimsenmesidir. Geleneksel çapa tabanlı tespit yöntemleri, her uygulama alanı için en uygun çapa setinin eğitim öncesinde belirlenmesini gerektirir. Bu süreç hem zaman alıcıdır hem de uygulama alanına özel optimizasyon gerektirir. Çapasız mekanizma, bu ek adımı ortadan kaldırarak tespit sürecini sadeleştirir. Ayrıca, çapa tabanlı mekanizmalar, cihazlar arasında çok sayıda tahminin taşınmasını gerektirerek potansiyel bir darboğaza neden olabilir. Çapasız

tasarım, bu tür sistem darboğazlarını ortadan kaldırırken, aynı zamanda genel tasarımı basitleştirir ve modelin parametre sayısını azaltır.

YOLOX'un üçüncü yeniliği, bir tane yerine birden fazla pozitif örnek kullanma stratejisidir. Geleneksel yöntemlerde, tahminlerin doğruluğunu artırmak için tek bir pozitif örnek üzerinden eğitim yapılırken, YOLOX çoklu pozitifler kullanarak yüksek kaliteli tahminlerin model tarafından öğrenilmesini sağlar. Bu yenilik, modelin daha genelleştirilebilir bir performans göstermesine katkıda bulunur.

Ge ve diğ. (2021), veri artırma (augmentation) teknikleriyle ilgili önemli gözlemler sunmuşlardır. Mozaik ve karıştırma gibi güçlü büyütme tekniklerinin büyük modellerin eğitimi için faydalı olduğunu, ancak aynı durumun küçük modeller için geçerli olmadığını belirtmişlerdir. Bu gözlem, farklı model ölçeklerine uygun veri artırma stratejilerinin seçilmesinin önemini vurgulamaktadır.

Sonuç olarak, YOLOX, modern nesne tespiti için optimize edilmiş bir mimari sunarak, doğruluk, hız ve esneklik açısından önemli avantajlar sağlamıştır. Çapasız mekanizma, ayrılmış kafa tasarımı ve çoklu pozitif kullanım gibi yenilikçi özellikleriyle YOLOX hem büyük hem de küçük ölçekli uygulamalarda güçlü bir nesne tespit modeli olarak öne çıkmaktadır. Decoupled Head ve SimOTA etiket atama stratejisi gibi yenilikçi yaklaşımları kullanarak, farklı model ölçeklerinde son teknoloji performansa ulaşmıştır. Örneğin, YOLOX-L modeli, COCO veri setinde %50,0 Ortalama Doğruluk (AP) elde ederken, Tesla V100 üzerinde 68.9 FPS hızında çalışmaktadır. Bu, YOLOv5-L modeline kıyasla %1,8 daha yüksek bir doğruluk oranı sunmaktadır.

3.2.2. Gold-YOLO

Gold-YOLO, nesne tespiti için geliştirilmiş modern bir model olup YOLO ailesinin bir türevidir. Model, özellikle enerji verimliliği ve performans arasında bir denge kurmayı hedefler ve uç cihazlarda düşük güç tüketimiyle çalışmaya uygun hale getirilmiştir (Zhou ve diğ., 2022). EfficientNet tabanlı bir omurga kullanan Gold-YOLO, görüntülerden düşük ve yüksek seviyeli özellikleri çıkarmada etkili bir yapı sunar. EfficientNet, modelin parametrelerini daha verimli kullanmasını sağlayan bir ölçekleme stratejisi içerir ve bu sayede model, düşük güç tüketimi ile yüksek performans sağlar (Tan ve Le, 2019). EfficientNet tabanlı omurga, Gold-YOLO'nun diğer YOLO modellerine kıyasla daha hafif bir yapıya sahip olmasını ve daha verimli çalışmasını mümkün kılar.

Gold-YOLO'nun boyun katmanında kullanılan Feature Pyramid Network (FPN), çok ölçekli özellik haritalarını birleştirerek modelin hem küçük hem de büyük nesneleri tespit etme yeteneğini artırır. Bu yapı, nesne tespiti sırasında kaybolabilecek detayları koruyarak modelin doğruluk oranını yükseltir (Lin ve diğ., 2017). Ayrıca, Gold-YOLO'nun kafa bölümü, çapa tabanlı bir yapı kullanır. Bu yöntem, nesnelerin boyutlarına ve konumlarına bağlı olarak önceden tanımlanmış çerçevelerle tahminleri karşılaştırır ve nesne tespitinde yüksek doğruluk oranı sağlar (Redmon ve Farhadi, 2016).

Gold-YOLO, GIoU (Generalized Intersection over Union) kayıp fonksiyonunu kullanarak çerçeve tahminlerini optimize eder. GIoU, tahmin edilen çerçevelerin gerçek çerçevelerle uyumunu değerlendirir ve klasik IoU kaybına kıyasla optimize bir sonuç sunar. Bu özellik, özellikle nesne sınırlarının doğru bir şekilde tespit edilmesini sağlayarak modelin doğruluğunu artırır (Zheng ve diğ., 2020). Enerji verimliliği açısından yapılan testlerde, Gold-YOLO'nun uç cihazlarda hem düşük çözünürlüklü hem de yüksek çözünürlüklü girişler için etkili sonuçlar verdiği gözlemlenmiştir (Zhou ve diğ., 2022).

Gold-YOLO-N modeli, COCO val2017 veri setinde %39,9 AP (Average Precision) elde etmiş ve T4 GPU üzerinde 1030 FPS hızına ulaşmıştır. Bu performansı, benzer FPS değerine sahip önceki SOTA modeli YOLOv6-3.0-N'yi %2,4 oranında geride bırakmıştır. Gold-YOLO'nun geliştirilmesinde, önceki modellerin bilgi birleştirme sorunlarını ele almak için Göm ve Dağıt (Gather-and-Distribute) mekanizması kullanılmıştır. Ayrıca, YOLO serisinde ilk kez MAE (Masked AutoEncoder) tarzı ön eğitim uygulanarak, denetimsiz ön eğitimden faydalanılması sağlanmıştır (Wang ve diğ., 2024).

3.2.3. YOLOv8

YOLOv8, nesne tespiti, segmentasyon ve sınıflandırma gibi görevlerde yüksek performans sunan, modern ve çok yönlü bir nesne tespiti modelidir. Önceki sürümlerin tasarım prensiplerini geliştirirken daha yüksek doğruluk ve enerji verimliliği sunmayı hedefler. Model, CSPNet (Cross-Stage Partial Network) tabanlı bir omurga kullanır ve bu yapı, bilgi akışını optimize ederek modelin parametre verimliliğini artırır (Wang ve diğ., 2020). CSPNet tabanlı omurga, hesaplama yükünü azaltırken modelin daha hızlı ve hafif çalışmasını sağlar. Bu özellik, YOLOv8'in hem yüksek doğruluk gerektiren hem de sınırlı kaynaklara sahip cihazlarda kullanılmasına olanak tanır.

YOLOv8'in boyun katmanı olarak kullanılan SPP (Spatial Pyramid Pooling), çok ölçekli özelliklerin birleşimini optimize eder ve farklı boyutlardaki nesnelerin daha hassas bir şekilde algılanmasını sağlar (He ve diğ., 2015). SPP, özellik haritalarını farklı alt bölgelere böler ve bu alt bölgelerden bilgi çıkararak modelin genel doğruluğunu artırır. Modelin kafa bölümü ise adaptif bir yapıya sahiptir ve tahminlerin farklı boyut ve sınıflar için özelleştirilmesini sağlar. Bu, modelin genel nesne tespit kapasitesini ve doğruluk oranını artırır.

YOLOv8'in kayıp fonksiyonları arasında DIoU (Distance Intersection over Union) ve CIoU (Complete Intersection over Union) öne çıkar. Bu fonksiyonlar, nesne tahminlerinin gerçek nesne konumlarıyla ne kadar örtüştüğünü değerlendirmek için geliştirilmiştir (Zheng ve diğ., 2020). DIoU kaybı, tahmin edilen çerçeve ile gerçek çerçeve arasındaki merkezi mesafeyi dikkate alırken, CIoU kaybı, yön ve boyut faktörlerini de hesaba katarak daha kapsamlı bir optimizasyon sunar. Bu kayıp fonksiyonlarının kullanılması, modelin daha doğru ve tutarlı tahminler yapmasını sağlar.

YOLOv8'in önceki YOLO modellerine göre sunduğu önemli bir avantaj, daha esnek ve optimize edilmiş bir yapıya sahip olmasıdır. Model, yüksek çözünürlükteki görüntülerde bile etkili nesne tespiti yaparken düşük çözünürlüklü girişlerde de yüksek doğruluk oranını koruyabilir. Bu özellik, uygulama senaryolarına göre ölçeklenebilirlik ve uyumluluk sağlar.

3.2.4. YOLOv9

YOLOv9, nesne tespiti algoritmalarında önceki sürümlerden önemli ölçüde farklılaşarak performans, verimlilik ve esneklik açısından yeni bir standart belirlemeyi amaçlayan bir modeldir. Bu model, modern sinir ağı mimarilerindeki en son yenilikleri entegre ederek hem teorik hem de pratik kullanımda üstünlük sağlamıştır.

YOLOv9'un omurga yapısı olarak Improved CSPNet (Cross-Stage Partial Network) kullanılır. CSPNet yapısı, parametre verimliliği sağlayarak modelin daha derin bir öğrenme kapasitesine sahip olmasını mümkün kılar. Özellikle, Gelişmiş CSPNet (Improved CSPNet), daha iyi özellik paylaşımı ve kanal bölünmesi ile daha dengeli bir öğrenme süreci sunar (Wang ve diğ., 2020). Bu yapı, görüntülerdeki düşük seviyeli ve yüksek seviyeli özellikleri aynı anda çıkararak hem küçük hem de büyük nesneleri algılama kapasitesini artırır.

YOLOv9'un boyun katmanı olarak Enhanced PANet (Path Aggregation Network) tercih edilmiştir. Bu katman, çok ölçekli nesne tespitine imkan tanıyan bir yapıyı benimseyerek özellik haritalarını birleştirir ve zenginleştirir (Liu ve diğ., 2018). Boyun katmanında ayrıca PGI (Pyramid Gradient Integration) yöntemi kullanılır. PGI, gradyan bilgilerini farklı seviyelerde entegre ederek modelin eğitimi sırasında daha etkin bir öğrenme süreci sağlar. PGI, özellikle çoklu ölçekli nesnelerin tespitinde model doğruluğunu artırır ve eğitim sırasında daha hızlı bir yakınsama sunar.

Modelin kafa bölümü, çok katmanlı birleştirme (multi-level fusion) stratejisi ile çalışır ve bu sayede farklı katmanlardan gelen özellikleri bir araya getirerek daha iyi bir nesne tespit doğruluğu sağlar. Kafa yapısında ayrıca GELAN (Generalized Label Assignment Network) teknolojisi kullanılır. GELAN, nesnelerin doğru sınıflandırılmasını ve sınır kutularının doğru bir şekilde belirlenmesini sağlayan dinamik etiket atama mekanizmasını içerir. Bu mekanizma, özellikle yoğun ve karmaşık sahnelerde tespit doğruluğunu artırmaktadır.

YOLOv9'un geliştirilmiş Unified Loss kayıp fonksiyonu, modelin daha verimli öğrenmesini sağlayan çok amaçlı bir yapı sunar. Unified Loss, hem sınır kutusu regresyonu hem de sınıflandırma hatalarını optimize ederek model performansını artırır (Zheng ve diğ., 2020). Özellikle, GELAN ile entegre edilen Unified Loss, karmaşık veri kümelerinde daha tutarlı sonuçlar elde edilmesini sağlar.

3.2.5. YOLOv10

YOLOv10, Ultralytics Python paketi temel alınarak geliştirilmiş ve önceki YOLO sürümlerinde bulunan mimari eksiklikleri, özellikle Non-Maximum Suppression (NMS) gibi yöntemlerin neden olduğu sınırlamaları ortadan kaldırmayı hedeflemiştir. YOLOv10, çeşitli model bileşenlerini optimize ederek, önemli ölçüde azaltılmış hesaplama yükü ile son teknoloji performansa ulaşmayı başarmıştır (Hussain, 2024). NMS ihtiyacını tamamen ortadan kaldırarak daha düşük gecikme ve gelişmiş hesaplama verimliliği sunan bu model, önceki YOLO sürümlerinin sunduğu yeniliklerin üzerine inşa edilmiştir.

YOLOv10'un en dikkat çekici özelliklerinden biri, NMS kullanımını devre dışı bırakabilen yenilikçi bir mimariye sahip olmasıdır. Geleneksel NMS, birden fazla tahminin aynı nesneye atanması durumunda fazla tahminleri eleyerek nesne tespitinin doğruluğunu artırırsa da, bu işlem hesaplama maliyetini artırır ve modelin basitliğini

azaltır. YOLOv10, İkili Atama Stratejisi (Dual Assignment Strategy, DAS) kullanarak NMS'ye olan bağımlılığı ortadan kaldırır ve sistemin yanıt süresini önemli ölçüde iyileştirmektedir.

YOLOv9'da tanıtılan GELAN mimarisi, çok ölçekli özelliklerin etkili bir şekilde entegre edilmesini sağlayarak YOLOv10'da da büyük bir rol oynamaktadır. GELAN, nesne tespiti ağ tasarımı esnek ve verimli bir yapı sunarak model performansını artırmıştır. YOLOv10, GELAN'ın bu yenilikçi yapısını daha da geliştirerek hem eğitim hem de çıkarım süreçlerinde etkili bir performans sunmaktadır.


DAS, Chen ve ekibinin (2022) yılında yaptığı çalışmaya dayanır ve tam evrişimli nesne tespit modellerinde kullanılan atama stratejilerini yeniden değerlendirerek modelin yakınsama hızını artırmayı ve genel performansı iyileştirmeyi hedefler. Geleneksel olarak, birden-çoğa (one-to-many) atama stratejisi kullanılarak birden fazla tahmin aynı gerçek nesneye atanır. Bu strateji, daha fazla pozitif örnek sağlayarak modelin eğitimini hızlandırır; ancak çıkarım sırasında yinelenen tahminleri ortadan kaldırmak için ek bir işlem olan NMS'ye ihtiyaç duyar.

Bir diğer yöntem olan birden-bire (one-to-one) atama stratejisi ise her gerçek nesneye yalnızca bir tahminin atanmasını sağlar ve çıkarım sürecini basitleştirir. Ancak, bu strateji daha az pozitif örnekle eğitim yapıldığından, modelin yakınsama hızını yavaşlatabilir ve performansı düşürebilir.

YOLOv10'da kullanılan DAS, her iki yaklaşımın avantajlarını birleştirerek eğitim sırasında iki ayrı dal oluşturur:

- Birden-Çoğa Atama Dalı: Geleneksel birden-çoğa stratejisiyle çalışarak daha fazla pozitif örnek sağlar ve modelin daha hızlı yakınsamasına katkıda bulunur.
- Birden-Bire Atama Dalı: Her gerçek nesneye yalnızca bir tahmin atayarak NMS ihtiyacını ortadan kaldırır ve çıkarım sırasında daha basit bir süreç sunar.

Eğitim süreci tamamlandıktan sonra, çıkarım işlemi yalnızca birden-bire atama dalı kullanılarak gerçekleştirilir. Bu yaklaşım, çıkarım performansını artırırken, NMS'nin neden olduğu ek hesaplama maliyetlerini ve karmaşıklığı ortadan kaldırır. Böylece, YOLOv10, daha hızlı ve verimli bir nesne tespiti sağlar. Eğitim tamamlandıktan sonra, yalnızca birden-bire atama dalı çıkarım için kullanılır (Şekil 3.6). Bu sayede, modelin çıkarım performansı artırılırken, NMS'nin getirdiği ek hesaplama maliyeti ve karmaşıklık ortadan kaldırılır.



Şekil 3.6. “Birden-Çoğa Atama” ve “Birden-Bire Atama” yapıları

Çizelge 3.6, tez çalışmasında kullanılan modellerin Omurga, Boyun, Kafa ve Kayıp Fonksiyonlarının yapılarını göstermektedir.

Çizelge 3.6. Modellerde kullanılan yöntemler

Model	Omurga	Boyun	Kafa	Kayıp Fonksiyonları
YOLOX	CSPDarknet	PANet	Anchor-Free	SimOTA
Gold-YOLO	EfficientNet-Based	FPN	Anchor-Based	GIoU Loss
YOLOv8	CSPNet	SPP	Adaptive Head	DIoU, CIoU
YOLOv9	Improved CSPNet	Enhanced PANet	Multi-Level Fusion	Unified Loss
YOLOv10	CSPNet-EfficientNet	Dynamic SPP + PANet	Advanced Anchor-Free	Hybrid IoU Loss

3.2.6. Obje tespit modelleri değerlendirme kriterleri

Obje tespit uygulamalarının performansını ölçmek için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), ortalama hassasiyet (AP), genel ortalama hassasiyet (GOH, mAP), kare hızı (FPS), hesaplama karmaşıklığı (FLOPs), kesişim-birleşim oranı (IoU) gibi metrikler kullanılmaktadır. Bu metriklerin hesaplanabilmesi için doğruluk tablosunun oluşturulması gerekmektedir. Doğruluk tablosu Çizelge 3.7’de verilmiştir. Bu tabloya göre;

Doğru Pozitif: Doğru şekilde tespit edilen pozitifler,

Doğru Negatif: Doğru şekilde tespit edilen negatifler,

Yanlış Pozitif: Yanlış şekilde pozitif olarak sınıflandırılanlar,

Yanlış Negatif: Yanlış şekilde negatif olarak sınıflandırılanlar şeklinde ifade edilir.

Çizelge 3.7. Doğruluk tablosu

		Gerçek Değer	
		Pozitif	Negatif
Tahmin Edilen Değer	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk tablosu kullanılarak oluşturulan ve performansı ölçen doğruluk, kesinlik, duyarlılık değerleri sırasıyla Eşitlik 3.1, Eşitlik 3.2 ve Eşitlik 3.3 ile hesaplanmıştır.

Doğruluk, modelin doğru tahminlerinin toplam tahminlere oranıdır.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.1)$$

Kesinlik, modelin pozitif olarak sınıflandırdığı tahminlerin ne kadarının doğru olduğunu ölçer.

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

Duyarlılık, modelin gerçek pozitif örnekleri doğru tespit etme oranıdır.

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

Genel ortalama hassasiyet değeri farklı IoU eşik değerlerinde modelin her sınıfı için ortalama hassasiyet değerinin hesaplanması ve ortalamasının alınmasıdır (Eşitlik 3.4). AP değeri kesinlik ve duyarlılık eğrisi çizildikten sonra eğrinin altında kalan alan olarak hesaplanmaktadır (Eşitlik 3.5). IoU eşik değeri, algılanan nesne ile yerel gerçek (ground truth) arasında kesişim ve birleşim oranını ölçer (Eşitlik 3.6).

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (3.4)$$

$$AP = \int_0^1 P(r) dr \quad (3.5)$$

Burada P kesinliği ifade ederken r duyarlılığı ifade etmektedir.

$$IoU = \frac{\text{Algılanan Alan ve Gerçek Alanın Kesişimi}}{\text{Algılanan ve Gerçek Alanın Birleşimi}} \quad (3.6)$$

3.3. Uç Cihazlar İçin Donanımlar

Tez çalışmasında, termal görüntüler üzerinde nesne tespiti için derin öğrenme tabanlı eğitilen nesne tespit modellerinin çalıştığı donanımlar, NVIDIA üreticisine ait Jetson Nano, Jetson Xavier NX, Jetson Orin Nano, Jetson Orin NX ve Rockchip üreticisine ait RK3588 donanımları kullanılmıştır.

3.3.1. NVIDIA Jetson Nano

NVIDIA Jetson Nano (Şekil 3.6), düşük güç tüketimi gerektiren uygulamalar için tasarlanmış, giriş seviyesi bir yapay zeka hesaplama platformudur. Kompakt yapısı ve verimli donanım bileşenleri sayesinde, eğitim amaçlı projelerden küçük ölçekli endüstriyel uygulamalara kadar geniş bir kullanım yelpazesine sahiptir (NVIDIA, 2019).



Şekil 3.6. Jetson Nano uç cihazı


Teknik Özellikler:

- CPU (İşlemci): Quad-core ARM Cortex-A57 işlemcisi, düşük güç tüketimi ile dengeli bir performans sağlamaktadır. Bu işlemci, temel hesaplama görevlerini kolayca yerine getirebilmektedir.
- GPU (Grafik İşlemci): 128 çekirdekli Maxwell mimarisine sahip grafik işlemcisi, yapay zeka iş yüklerinde de kullanılmaktadır. Görüntü işleme, nesne tespiti ve basit derin öğrenme uygulamaları için grafik işlem gücüne sahiptir.
- Bellek (RAM): 4 GB LPDDR4 RAM kapasitesine sahiptir.
- Yapay Zeka Performansı: Yaklaşık 0.5 TFLOPs'a kadar çıkabilen hesaplama kapasitesi, temel düzeyde yapay zeka algoritmalarını çalıştırmak için uygundur.
- Güç Tüketimi: 5 ila 10 watt arasında değişen güç tüketimi, Jetson Nano'yu düşük enerji gereksinimi olan taşınabilir ve batarya destekli uygulamalar için kullanılabilir yapmaktadır (NVIDIA, 2019).

Kompakt boyutu, düşük güç tüketimi, Linux tabanlı işletim sistemi ve açık kaynaklı yazılım desteği sayesinde, uç cihazlarda verimli ve geniş kapsamlı bir kullanım imkanı sunmaktadır.

3.3.2. NVIDIA Jetson Xavier NX

NVIDIA Jetson Xavier NX (Şekil 3.7), yüksek performans ve enerji verimliliği gerektiren uygulamalar için tasarlanmış, gelişmiş bir yapay zeka hesaplama platformudur. Kompakt yapısı ve güçlü donanım bileşenleri sayesinde, karmaşık endüstriyel projelerden gelişmiş robotik uygulamalara kadar geniş bir kullanım yelpazesine sahiptir (NVIDIA, 2020).



Şekil 3.7. Jetson Xavier NX uç cihazı ve mimarisi


Teknik Özellikler:

- CPU (İşlemci): 6 çekirdekli NVIDIA Carmel ARM v8.2 64-bit CPU, yüksek performans ile enerji verimliliğini birleştiren bir yapıya sahiptir. Bu işlemci, karmaşık hesaplama görevlerini düşük gecikme ile kolayca gerçekleştirebilmektedir.
- GPU (Grafik İşlemci): 384 çekirdekli Volta mimarisine sahip grafik işlemcisi, 48 Tensor Core ile güçlendirilmiştir. Bu yapı, derin öğrenme modelleri ve yapay zeka iş yüklerinde üstün performans sunmakta, görüntü işleme, nesne tespiti ve diğer yoğun yapay zeka uygulamaları için optimize edilmiş grafik işlem gücü sağlamaktadır.
- Bellek (RAM): 8 GB veya 16 GB LPDDR4x RAM kapasitesine sahiptir.
- Yapay Zeka Performansı: Yaklaşık 21 TOPS (Tera Operations Per Second) hesaplama kapasitesine sahiptir. Bu performans, karmaşık yapay zeka algoritmalarını ve gerçek zamanlı veri analizi işlemlerini gerçekleştirebilmeyi sağlamaktadır.
- Güç Tüketimi: 10 ila 15 watt arasında değişen enerji tüketimi, Jetson Xavier NX'i enerji verimliliği gerektiren taşınabilir uygulamalar ve otonom sistemler için kullanılabilir haline getirmektedir.

Karmaşık yapay zeka algoritmalarını işleyebilme, kompakt boyut, düşük güç tüketimi, Linux tabanlı işletim sistemi ve açık kaynaklı yazılım desteği sayesinde, uç cihazlarda verimli ve geniş kapsamlı bir kullanım imkanı sunmaktadır.

3.3.3. NVIDIA Jetson Orin Nano

NVIDIA Jetson Orin Nano (Şekil 3.8), giriş seviyesi yapay zeka projeleri için tasarlanmış, yüksek performans ve enerji verimliliğini bir arada sunan güçlü bir uç hesaplama platformudur. Kompakt yapısı ve modern donanım bileşenleri sayesinde, robotik, IoT ve görüntü işleme gibi çeşitli alanlarda geniş bir kullanım yelpazesine sahiptir (NVIDIA, 2022).



Şekil 3.8. Jetson Orin Nano uç cihazı ve mimarisi

Teknik Özellikler:

- CPU (İşlemci): 8 çekirdekli ARM Cortex-A78AE işlemci, yüksek performanslı hesaplama görevlerini düşük güç tüketimiyle yerine getirebilecek şekilde tasarlanmıştır. Bu işlemci, modern yapay zeka uygulamalarının ihtiyaç duyduğu hız ve verimliliği sağlamaktadır.
- GPU (Grafik İşlemci): 1024 çekirdekli NVIDIA Ampere mimarisi grafik işlemcisi ve 32 Tensor Core ile donatılmıştır. Bu yapı, görüntü işleme, nesne tespiti ve diğer yoğun yapay zeka görevleri için kullanılabilir durumdadır..
- Bellek (RAM): 4 GB veya 8 GB LPDDR5 RAM kapasitesine sahiptir.
- Yapay Zeka Performansı: 40 TOPS hesaplama kapasitesiyle, temel ve orta düzey yapay zeka uygulamaları için uygun bir platformdur. Bu değer, gelişmiş veri analizi ve model çalıştırma yeteneğini ifade etmektedir.
- Güç Tüketimi: 7 ila 15 watt arasında değişen enerji tüketimi, Jetson Orin Nano'yu taşınabilir cihazlar ve enerji sınırlamaları olan sistemlerde kullanıma uygun hale getirmektedir.

NVIDIA Jetson Orin Nano, kompakt boyutu, düşük güç tüketimi ve modern donanım özellikleriyle, giriş ve orta seviye yapay zeka uygulamaları için etkili bir donanım çözümü sağlamaktadır. 40 TOPS yapay zeka performansı, uç cihazlardan otonom sistemlere kadar geniş bir uygulama alanında kullanılmasına olanak tanır. Linux tabanlı işletim sistemi ve NVIDIA yazılım ekosistemi sayesinde, geliştiricilere yüksek esneklik ve uyarlanabilirlik sunmaktadır.

3.3.4. NVIDIA Jetson Orin NX

NVIDIA Jetson Orin NX (Şekil 3.9), kompakt boyutuna rağmen yüksek yapay zeka performansı sunan, gelişmiş bir uç hesaplama platformudur. Gelişmiş GPU ve CPU mimarisi ile zengin bellek seçenekleri, yoğun yapay zeka iş yükleri ve gerçek zamanlı uygulamalar için uç cihaz çözümü sağlamaktadır. Otonom sistemlerden robotik uygulamalara kadar geniş bir kullanım alanına hitap etmektedir (NVIDIA, 2022).



Şekil 3.9. Jetson Orin NX uç cihazı

Teknik Özellikler:


- CPU (İşlemci): 8 çekirdekli ARM Cortex-A78AE işlemcisi, yüksek performanslı veri işleme ve hesaplama görevlerini enerji verimliliği ile birleştirilmiştir. Bu işlemci, karmaşık algoritmaların hızlı ve güvenilir bir şekilde çalışmasını sağlamaktadır.
- GPU (Grafik İşlemci): 1024 çekirdekli NVIDIA Ampere mimarisine sahip GPU, 64 Tensor Core ile güçlendirilmiştir. Bu yapı, yoğun yapay zeka görevlerini (örneğin, derin öğrenme ve bilgisayarla görme) desteklemek için optimize edilmiştir.
- Bellek (RAM): 8 GB veya 16 GB LPDDR5 RAM seçenekleri bulunmaktadır.
- Yapay Zeka Performansı: 100 TOPS kapasitesi, gerçek zamanlı ve yoğun yapay zeka işlemleri için üstün bir performans sağlar. Bu değer, gelişmiş algoritmaların paralel olarak çalıştırılmasını mümkün kılmaktadır.
- Güç Tüketimi: 10 ila 25 watt arasında değişen güç tüketimi, yüksek performans gerektiren uygulamalar için enerji verimliliği sağlamaktadır.

NVIDIA Jetson Orin NX, 100 TOPS yapay zeka işleme gücü, modern donanım bileşenleri ve kompakt tasarımıyla, karmaşık ve yoğun yapay zeka uygulamaları için bir

uç cihaz platformudur. Güçlü performansı, geniş yazılım desteği ve enerji verimliliği sayesinde, otonom sistemler, robotik, IoT ve endüstriyel projeler gibi çeşitli alanlarda kapsamlı çözümler sunmaktadır.

3.3.5. Rockchip RK3588

Rockchip RK3588 (Şekil 3.10), gelişmiş yapay zeka ve çoklu medya işleme gerektiren uygulamalar için tasarlanmış, yüksek performanslı ve enerji verimli bir System on Chip (SoC) yapısıdır. Çeşitli CPU, GPU ve NPU bileşenleri sayesinde geniş bir kullanım yelpazesine hitap etmektedir. IoT, uç cihazlar, akıllı ekranlar ve endüstriyel uygulamalar gibi alanlarda yenilikçi çözümler sunmaktadır.



Şekil 3.10. Rockchip RK3588 uç cihazı ve mimarisi

Teknik Özellikler:

- CPU (İşlemci): 4 çekirdekli Cortex-A76 ve 4 çekirdekli Cortex-A55 kombinasyonuna sahiptir. Büyük-küçük işlemci mimarisi sayesinde hem yüksek performanslı hem de enerji tasarruflu işlemler için optimize edilmiştir. 64-bit mimarisiyle gelişmiş hesaplama görevlerini desteklemektedir.
- GPU (Grafik İşlemci): Mali-G610 MP4 grafik işlemcisi ile yüksek çözünürlüklü görüntü işleme ve 3D grafik işleme kapasitesine sahiptir. 8K çözünürlükte video oynatma ve kodlama desteği sunmaktadır.
- Bellek (RAM): LPDDR4 ve LPDDR5 desteği ile 32 GB'a kadar haricen bağlanan RAM kapasitelerini desteklemektedir.

- Yapay Zeka Performansı (NPU): 6 TOPS yapay zeka işleme kapasitesine sahiptir.
- Bağlantı: PCIe 3.0, USB 3.1, HDMI 2.1, ve DisplayPort 1.4 desteği bulunmaktadır. Gelişmiş bağlantı özellikleri, çoklu ekran desteği bulunmaktadır.
- Güç Tüketimi: Düşük güç tüketimiyle enerji verimli bir çalışma sağlar. Bu özellik, taşınabilir ve enerji sınırlamaları olan sistemler için büyük bir avantajdır.

Rockchip RK3588, gelişmiş işlemci ve grafik yetenekleriyle modern teknolojik uygulamalara güçlü bir çözüm sunmaktadır. Yüksek performansı, geniş bağlantı seçenekleri ve enerji verimliliği, bu platformu batarya ile çalışacak şekilde tasarlanan IoT, akıllı cihazlar ve medya uygulamaları için ideal bir seçim haline getirmektedir. Özellikle yapay zeka ve medya uygulamaları için optimize edilmiş özellikleri sayesinde, endüstriyel ve ticari projelerde güçlü bir rekabet avantajı sağlamaktadır.

3.4. Uç Cihazların Performans Ölçümleri İçin Standartlar

Uç cihazların performans ölçümünde, donanım ve yazılım için farklı performans kriterleri dikkate alınmaktadır. Bu çalışmada yazılım performansı, yapay zeka temelli obje tespit modellerinin değerlendirilmesi üzerine odaklanmıştır. Obje tespit modelleri için performansı ifade eden en önemli kriter, GOH değeri olarak belirlenmiştir. GOH, modelin her bir sınıf için tahmin ettiği değerlerinden elde edilen kesinlik-duyarlılık (precision-recall) eğrisi altında kalan alanların ortalamasını ifade etmektedir ve modellerin doğruluk performansını belirlemede kritik bir rol oynamaktadır.

Donanım performansı iki temel ölçüm kriteri ile değerlendirilmiştir. Bunlardan ilki, saniye başına analiz edilen kare sayısını ifade eden FPS değeridir. İkincisi ise uç cihazın işlem esnasında tükettiği güç miktarıdır. FPS değeri, yazılım içinde ilgili kod eklentileri ile doğrudan ölçülebilen, güç tüketimi bir ölçüm cihazı kullanılarak gerçekleştirilmektedir. Ayrıca bir diğer performans ölçüm metriği olarak güç başına üretilen FPS değeri (FPS/Watt) değeri hesaplanmıştır (Darío ve diğ., 2024).

3.5. Uç Cihazlar Arası Haberleşme

Uç cihazlar, bant genişliği, gecikme süreleri ve enerji tüketimi gibi kısıtlamalarla karşı karşıya kalan sistemlerdir. Genellikle sınırlı bant genişliğine sahip olan bu cihazlar, görüntü verilerinin etkili bir şekilde sıkıştırılması ve iletilmesini gerektirir. Özellikle otonom araçlar gibi gerçek zamanlı karar verme süreçleri gerektiren uygulamalarda,

düşük gecikme süreleri kritik öneme sahiptir ve bu gereksinim, haberleşme protokollerinin seçiminde belirleyici bir faktör olarak öne çıkmaktadır. Bunun yanı sıra, uç cihazların enerji kısıtlamaları dikkate alındığında, performanstan ödün vermeden uzun süreli çalışmayı mümkün kılan enerji verimli haberleşme protokollerinin kullanılması büyük önem taşımaktadır. Bu bağlamda, uç cihazlar için optimize edilmiş iletişim sistemleri, modern teknolojinin gerekliliklerine yanıt veren yenilikçi çözümler sunmayı hedeflemektedir.

Uç cihazlar arasında görüntü iletimi için görüntü verilerinin sıkıştırılması ve aktarımında yaygın olarak kullanılan GStreamer kütüphanesi tercih edilmiştir. GStreamer, modüler yapısı ve esnek kullanım özellikleriyle, çoklu medya işleme ve iletimi süreçlerinde öne çıkan bir araçtır. Özellikle, UDP (User Datagram Protocol) haberleşme protokolü üzerinden düşük gecikme süreleri sağlanmış ve etkili bir veri aktarımı gerçekleştirilmiştir. UDP, bağlantısız bir protokol olması sayesinde, özellikle gerçek zamanlı veri iletimi gereksinimi olan uygulamalarda tercih edilen bir çözümdür.

Sonuç olarak, GStreamer kütüphanesi ve UDP protokolünün bir arada kullanılması, uç cihazlar arasında verimli, düşük gecikmeli ve enerji tasarruflu bir görüntü iletim sistemi oluşturulmasına katkı sağlamaktadır.

3.5.1. Gstreamer kütüphanesi

GStreamer, medya uygulamalarının geliştirilmesini kolaylaştırmak için tasarlanmış, açık kaynaklı ve çapraz platform uyumlu bir multimedya çerçevesidir. Çeşitli ses ve video akışlarının işlenmesini sağlayan kapsamlı bir boru hattı (pipeline) mimarisi sunar. GStreamer'ın mimarisi modüler bir yapıya sahiptir ve bir çekirdek yapı ile çok sayıda eklentiden oluşur.

- Çekirdek: Veri akışını ve senkronizasyonu yönetir.
- Eklentiler: Kodlama, kod çözme, filtreleme ve görüntüleme gibi belirli görevleri yerine getirir.

Bu modüler yapı, geliştiricilerin çeşitli elemanları birbirine bağlayarak karmaşık multimedya boru hatları oluşturmasını sağlar. Bu esneklik, farklı uygulamalarda geniş bir kullanım alanı yaratır. Python gibi farklı programlama dillerinde video yakalama ve kodlama işlemleri için kullanılmıştır (Wang ve diğ., 2017). GStreamer, yüksek tanımlı video akışlarını minimum gecikme ile işlemek için yüksek performans sunar. Donanım hızlandırmayı destekleyen yapısı sayesinde, masaüstü bilgisayarlardan uç cihazları

barındıran sistemlere kadar farklı cihazlarda etkili bir şekilde çalışır. Yapılan çalışmalar, düşük gecikme süresi ve yüksek veri işleme kapasitesi ile gerçek zamanlı video akışı uygulamalarında etkili olduğunu göstermektedir (Nimmi ve diğ., 2014).

3.5.2. User Datagram Protocol (UDP) haberleşme


User Datagram Protocol (UDP), bağlantısız yapısı ve minimal protokol mekanizmasıyla IP (Internet Protocol) ailesinin temel iletişim protokollerinden biridir. Düşük gecikme süresi sayesinde UDP, bağlantı kurma ve onay süreçlerini içermediğinden iletim gecikmelerini en aza indirir. Bu sayede canlı video akışı ve etkileşimli video konferansı gibi gerçek zamanlı uygulamalarda tercih edilen yöntem haline gelmiştir (Kim ve diğ., 2022). Ayrıca basitleştirilmiş protokol yükü ile UDP, bant genişliğinin daha verimli kullanılmasını sağlar. Bu, sınırlı kaynaklara sahip ağlarda büyük boyutlu görüntü veya video dosyalarının iletilmesi için avantaj sağlar (Soomro ve diğ., 2018). Bununla birlikte UDP'nin hata düzeltme veya yeniden iletim mekanizmalarına sahip olmadığından, iletim sırasında paket kaybı meydana gelebilir. Bu durum, görüntü kalitesinin bozulmasına veya eksik veri alınmasına yol açabilir. Bağlantısız yapısı nedeniyle UDP, paketlerin sırasız teslim edilmesine neden olabilir. Bu durum, görüntü verisinin doğru bir şekilde yeniden yapılandırılması için uygulama katmanında ek işlemlere ihtiyaç duymaktadır (Soomro ve diğ., 2018).

UDP ile veri iletimi esnasında karşılaşılan zorlukların aşılması için ilk yöntem İleri Hata Düzeltme (Forward Error Correction- FEC) yöntemidir. FEC teknikleri, kaybolan paketlerin yeniden iletimine ihtiyaç duymadan kurtarılmasına yardımcı olur. Bu yöntem hem görüntü kalitesini korur hem de gecikme süresini azaltır (Chang ve diğ., 2013). Diğer bir yöntem ise Gerçek Zamanlı Taşıma Protokolü (RTP) protokolüdür ve UDP üzerine eklenerek sıralama ve zaman damgası desteği sağlar. Bu, görüntü verisinin doğru bir şekilde senkronize edilmesine ve sıralanmasına yardımcı olur (Mohammed ve diğ., 2023).

UDP, görüntü aktarımı için düşük gecikme ve minimal protokol yükü gibi önemli avantajlar sunarken, güvenilirlik ve veri bütünlüğü gibi zorlukları da beraberinde getirir. Bu zorluklar, uygun çözüm stratejileri ve destekleyici protokoller kullanılarak aşılabılır. Sonuç olarak, UDP, uygun şekilde optimize edildiğinde, görüntü aktarımı için etkili ve verimli bir çözüm sunmaktadır.

4. ARAŞTIRMA SONUÇLARI

Bu bölümde tez çalışmasında için kullanılan termal veri setinin özelleştirilmesi, obje tespit modellerinin termal veri seti ile eğitilmesi, uç cihaz performansının artırılması için yapılan değişiklikler, tanımlanan yeni performans metrikleri, uç cihazların birbiri ile haberleşmesi için geliştirilen yöntem anlatılmaktadır (Şekil 4.1).



Şekil 4.1. Uç cihazlar için yapılan çalışmanın blok diyagramı

4.1. Termal Veri Setinin Oluşturulması

Bu çalışmada, obje tespit modellerinin termal veri seti ile eğitilmesi için Teledyne FLIR veri seti insan ve araç olacak şekilde iki sınıflı hale getirilerek sadeleştirilmiştir. Yeni oluşturulan eğitim veri setinde toplam 8681 görüntü kullanılmıştır. Aynı görüntü içerisinde birden fazla insan ve aracın etiketlenmesi sonucunda, veri setinde toplam 36963 araç ve 21265 insan görüntüsü yer almaktadır. Yapay görüntü artırma yöntemleri (Parlaklık, Satürasyon, Pozlama, Bulanıklık, Gürültü) ile artırılan veriler, eğitim için 12000, validasyon için 1200 ve test için 1200 görüntüden oluşan veri seti paketi haline getirilmiştir (Çizelge 4.1).

Çizelge 4.1. İki sınıf için özelleşmiş Teledyne FLIR veri seti

Toplam Görüntü	Eğitim Verisi	Test Verisi	Validasyon Verisi	Toplam Etiketli Veri	Etiketli Araç Sayısı	Etiketli İnsan Sayısı
8681	12000	1200	1200	58228	36963	21265

4.1.1. Termal veriler ile gerçek dünya test ortamının hazırlanması

Termal kameralar, farklı ışık koşullarında, nesne sıcaklıklarına bağlı olarak değişen görüntüler üretir. Gerçek dünya ortamlarını simüle etmek için termal görüntülere aşağıdaki değişiklikler uygulanmıştır.


Parlaklık: $\pm 25\%$ arasında değişen parlaklık ayarları uygulanarak, düşük ışık veya yüksek parlaklık koşullarında elde edilen termal görüntüler simüle edilmiştir. Bu, modelin farklı çevresel koşullara karşı daha dayanıklı hale gelmesini sağlamıştır. Örnek görüntü Şekil 4.2’de gösterilmektedir.

Şekil 4.2. $\pm 25\%$ parlaklık uygulanan görüntü

Satürasyon: Termal görüntülerde renk doygunluğu, farklı sıcaklık değerlerini temsil eder. Doygunluk seviyeleri, $\pm 40\%$ arasında değiştirilerek, farklı termal kontrast düzeylerine sahip görüntüler oluşturulmuştur (Şekil 4.3). Bu işlem, modelin hem düşük kontrastlı hem de yüksek kontrastlı termal görüntüleri öğrenmesine olanak tanımıştır.

Şekil 4.3. $\pm 40\%$ satürasyon uygulanan görüntü

Bulanıklık: Görüntülere 1.5 piksele kadar bulanıklık uygulanmıştır. Bu, özellikle hareketli nesnelerin termal görüntülerinde oluşabilecek bulanıklığı simüle ederek, modelin bu tür verilerde de doğru tahmin yapabilme yeteneğini geliştirmiştir. Örnek görüntü Şekil 4.4’de gösterilmektedir.



Şekil 4.4. 1.5 piksel bulanıklık uygulanan görüntü

Gürültü: Görüntünün %4'üne kadar rastgele piksel gürültüsü eklenerek, düşük kaliteli termal sensörlerin veya dış ortamlardan gelen parazitlerin temsili yapılmıştır. Bu işlem, modelin gürültülü verilerdeki performansını artırmayı hedeflemiştir. Örnek görüntü Şekil 4.5’de gösterilmektedir.



Şekil 4.5. %4 gürültü uygulanan görüntü

Ayrıca, model eğitimi tamamlandıktan sonra, gerçek dünya koşullarında modelin performansını test etmek amacıyla DSIAC veri setindeki görüntüler kullanılarak videolar oluşturulmuştur. Bu videolar, farklı mesafelerden kaydedilen hareketli nesneleri içermekte olup, modelin gerçek dünya verilerine karşı dayanıklılığı ve genel performansı değerlendirilmiştir. Gerçek dünya koşullarını daha iyi yansıtmak için, oluşturulan bu videolar eğitim veri setine dahil edilmemiştir. Bu yaklaşım, modelin tamamen yeni ve daha önce görmediği verilere karşı olan performansını ölçmeyi mümkün kılmıştır.

Böylece, modelin genelleme yeteneği ve gerçek dünyadaki senaryolara uygunluğu test edilmiştir.

Yakın mesafeden kaydedilen hareketli nesneler, detayların yüksek olduğu senaryoları temsil etmiştir. Bu görüntüler, modelin ayrıntılı termal özellikleri tanıyıp tanımadığını değerlendirmek için kullanılmıştır. Uzak mesafeden kaydedilen nesneler, çözünürlüğün ve detayların azaldığı durumları simüle etmiştir. Modelin düşük çözünürlüklü ve zorlu koşullardaki performansı test edilmiştir. Hareketli nesnelerin yavaş ve hızlı geçişleri simüle edilerek, modelin hareketli hedefleri algılama ve izleme yetenekleri analiz edilmiştir.

4.2. Obje Tespit Modellerinin Termal Veri Seti ile Eğitilmesi

Her model, giriş çözünürlüğü 640x640 piksel olarak belirlenen termal veri seti ile eğitilmiştir. Bu çözünürlük, termal görüntülerin işlenmesinde önemli bir denge sağlayarak hem hesaplama maliyetlerini kontrol altında tutmuş hem de görüntü içeriğindeki detayların kaybolmasını engellemiştir. Bu çözünürlük değeri, farklı uygulama senaryolarında yeterli görsel bilgi sağlarken, obje tespit modellerinin karşılaştırılmasında standart bir boyut olarak kabul edilmektedir.

Eğitim sürecinde, her model için önceden belirlenmiş ve varsayılan olarak kaydedilmiş parametre değerleri kullanılmıştır. Bu parametrelerde herhangi bir değişiklik yapılmaması, model eğitiminin tüm aşamalarında tutarlılık sağlamıştır. Standart parametrelerle çalışılması, modellerin performansını dış etkenlerden bağımsız olarak değerlendirme imkânı tanımış ve farklı modeller arasındaki karşılaştırmaların adil bir şekilde yapılmasını mümkün kılmıştır. Bu yaklaşım, modelin genelleme yeteneğini artırarak yeni veri setleriyle olan uyumluluğunu test etmede önemli bir avantaj sunmuştur.

Eğitilecek her modelin en düşük parametre sayısına sahip dağıtımı kullanılmıştır. Bu, yalnızca eğitim süresini kısaltmakla kalmamış, aynı zamanda donanım kaynaklarını daha verimli kullanarak enerji maliyetlerini de azaltmıştır. Hafif parametrelili modeller, özellikle kaynak sınırlamalarına sahip uç cihazlarda kullanımı kolaylaştırmış ve gerçek zamanlı uygulamalara uygun hale getirilmiştir. Parametre sayısının düşürülmesi, hesaplama gereksinimlerinin azalmasına katkıda bulunmuş ve bu durum, daha hızlı ve daha verimli bir eğitim süreci sağlamıştır. Çizelge 4.2’de eğitim sonucunda elde edilen doğruluk oranlarını görülmektedir.

Çizelge 4.2. Obje tespit modelleri için termal veri seti ile eğitim sonrası doğruluk değerleri

Model Adı	Çözünürlük	Genel Ortalama Hassasiyet	Parametre Sayısı (M)
YOLOX-n	224x224	%54,5	0,91
	320x320	%60,3	
	512x512	%67,2	
	640x640	%70,3	
Gold-YOLO-n	224x224	%62,5	5,6
	320x320	%73,5	
	512x512	%83,6	
	640x640	%85,2	
YOLOv8-n	224x224	%55,7	3,2
	320x320	%76,3	
	512x512	%85,2	
	640x640	%87,7	
YOLOv9-t	224x224	%61,4	2
	320x320	%75,2	
	512x512	%85,1	
	640x640	%87,6	
YOLOv10-n	224x224	%63,5	2,3
	320x320	%75,4	
	512x512	%84,5	
	640x640	%86,2	

224x224 piksel çözünürlükte, en yüksek GOH değerini (%63,5) YOLOv10-n modeli elde etmiştir. Gold-YOLO-n modeli ise düşük çözünürlükte oldukça iyi bir performans (%62,5) sergilemiş, ancak yüksek parametre sayısı (5,6M) sebebiyle düşük kapasiteli uç cihazlarda kullanımının sınır olacağı değerlendirilmektedir. Diğer taraftan, YOLOX-n ve YOLOv8-n modelleri sırasıyla %54,5 ve %55,7 GOH ile diğer modellere kıyasla daha düşük performans sergilemiştir.

320x320 piksel çözünürlük seviyesinde, YOLOv8-n modeli (%76,3) ve YOLOv9-t modeli (%75,2) öne çıkmaktadır. Bunun yanı sıra, YOLOv10-n modeli %75,4 GOH değeriyle dikkat çekici bir performans sergilemiştir. Gold-YOLO-n, %73,5 GOH ile kabul edilebilir sonuçlar sunmuş olsa da yüksek parametre sayısı nedeniyle verimlilik

açısından dezavantajlıdır. YOLOX-n modeli ise %60,3 GOH ile diğer modellere kıyasla daha düşük bir başarı düzeyi göstermiştir.

512x512 çözünürlük seviyesinde, YOLOv8-n (%85,2) ve YOLOv9-t (%85,1) modelleri en yüksek performansı sağlamıştır. Ancak, YOLOv9-t modeli, daha düşük parametre sayısı (2M) ile daha az kaynak gereksinimi sunarak avantaj sağlayacağı değerlendirilmiştir. Gold-YOLO-n, %83,6 GOH ile üçüncü sırada yer almıştır. YOLOv10-n modeli ise %84,5 GOH ile bu çözünürlükte daha yüksek sonuç elde etmiştir.

640x640 çözünürlük seviyesinde, en yüksek genel ortalama hassasiyet değeri (%87,7) YOLOv8-n modeli tarafından elde edilmiştir. YOLOv9-t modeli ise %87,6 GOH ile ikinci sırada yer almış ve daha düşük parametre sayısı (2M) sayesinde verimlilik açısından güçlü bir alternatif sunmuştur. YOLOv10-n modeli %86,2 GOH ile bu çözünürlük seviyesinde iyi bir performans sergilemiş, ancak YOLOv8-n ve YOLOv9-t modellerinin gerisinde kalmıştır. Gold-YOLO-n, %85,2 GOH ile nispeten düşük bir performans göstermiştir.

Sonuç olarak, analiz edilen modeller arasında, YOLOv8-n ve YOLOv9-t, yüksek çözünürlüklerde üstün performans ve verimlilik sunmaları nedeniyle tercih edilebilir modeller olarak öne çıkmaktadır. YOLOv10-n, 240x240 piksel çözünürlüğünde daha fazla başarısı ile dikkat çekmekte, ancak diğer çözünürlüklerde geride kalmaktadır. Gold-YOLO-n, özellikle yüksek parametre sayısı nedeniyle kaynak kullanımı açısından sınırlı bir seçenek olarak değerlendirilmektedir. YOLOX-n, düşük performansı sebebiyle diğer modellere kıyasla rekabet avantajı sağlayamamaktadır, buna karşın sınırlı kaynaklara sahip uç cihazlarda daha verimli çalışacağı düşünülerek alternatif oluşturmaktadır.

4.3. Uç Cihazların Performans Ölçümleri

Tez çalışması kapsamında FLIR Termal veri seti kullanılarak oluşturulan termal veri seti ile eğitilen YOLOX, Gold-YOLO, YOLOv8, YOLOv9 ve YOLOv10 obje tespit modellerinin performansları, çeşitli uç cihazlar üzerinde detaylı bir şekilde analiz edilmiştir. Her modelin giriş çözünürlüğü sırasıyla 224x224, 320x320, 512x512 ve 640x640 piksel olarak belirlenmiş, bu farklı çözünürlüklerdeki performans parametreleri sistematik olarak kayıt altına alınmıştır. Çözünürlük varyasyonu, modellerin farklı görsel detay seviyelerinde işleme yeteneklerini ve cihaz kaynakları üzerindeki etkilerini anlamak için yapılmıştır. Çalışmada, modellerin Jetson Nano, Jetson Xavier NX, Jetson Orin Nano, Jetson Orin NX ve RK3588 gibi uç cihazlarda çalıştırılması esnasında ölçülen

değerler ile elde edilen metrikler üzerinden analiz edilmesi hedeflenmiştir. Bu analiz kapsamında üç temel performans göstergesi dikkate alınmıştır: FPS değeri, harcanan güç miktarı (Watt) ve hesaplanan FPS/Watt oranı. Bu metrikler hem modellerin hem de uç cihazların enerji verimliliği ve işleme hızını kıyaslamak için önemli veriler sağlamıştır.

Her bir cihaz üzerinde çalıştırılan modellerden elde edilen FPS değerleri, işlem hızını ve gerçek zamanlı uygulamalara uygunluğunu belirlerken, harcanan güç miktarı cihazların enerji tüketim performansını değerlendirmede kullanılmıştır. Ayrıca FPS/Watt oranı, cihazların enerji verimliliğini ölçerek, yüksek performans ile düşük enerji tüketimi sağlayan kombinasyonları tespit etmek için kritik bir metrik olmuştur. Bu ölçümler, özellikle uç cihazların enerji sınırlamalarına sahip ortamlarda (örneğin, taşınabilir cihazlar, silah üstü sistemler, giyilebilir cihazlar) kullanılabilirliğini anlamak açısından önemlidir. Bununla birlikte modellerin genel başarımlarının değerlendirilmesi amacıyla yalnızca FPS, güç tüketimi ve enerji verimliliği (FPS/Watt) değil, aynı zamanda tespit doğruluğunu ifade eden GOH değerinin de dikkate alındığı yeni bir performans ölçüm puanlaması geliştirilmiştir. Bu puanlama, "Donanım için Uygunluk Sıralaması" (Ranking of Suitability for Hardware, RSH) olarak adlandırılmıştır (Eşitlik 4.1). RSH, her uç cihazın ayrı ayrı değerlendirilmesiyle, test yapılan uç cihaz için en uygun modeli tespit etmek amacıyla kullanılabilir.

$$RSH = GOH \times \frac{FPS}{Watt} \quad (4.1)$$

Bunun yanında, test edilen model ve uç cihazların tamamının performansını doğru bir şekilde kıyaslamak için, model giriş çözünürlüğünün de hesaplamalara dahil edildiği yeni bir performans puanlaması daha geliştirilmiştir. Bu puanlama sistemi, "Donanım ve Algoritmik Verim İçin Uygunluk Sıralaması" (Ranking of Suitability for Hardware and Algorithmic Yield, RSHAY) olarak adlandırılmıştır (Eşitlik 4.5). RSHAY, çözünürlük, GOH ve enerji verimliliğini bir arada değerlendirerek, tüm modellerin ve donanımların genel karşılaştırmasını sağlamaktadır.

$$\alpha = \sqrt{\frac{G\zeta_x \times G\zeta_y}{M\zeta_x \times M\zeta_y}} \quad (4.2)$$

$$m = \frac{GOH}{\sqrt{\ln(e + \alpha)}} \times 100 \quad (4.3)$$

$$f = \frac{fps}{watt} \times \ln\left(\frac{\alpha}{e^\pi} + 1\right) \quad (4.4)$$

$$RSHAY = m \times f \quad (4.5)$$

Verilen eşitliklerde tanımlanan α değeri, modelin giriş çözünürlüğünün minimum çözünürlükle normalize edilmiş formunu ifade etmektedir. Burada, $G\zeta_x$ ve $G\zeta_y$ sırasıyla giriş çözünürlüğünün x ve y eksenindeki değerlerini, $M\zeta_x$ ve $M\zeta_y$ ise YOLO mimarisi için minimum giriş çözünürlüğünü temsil etmektedir. YOLO mimarisi için teorik olarak belirlenen en düşük giriş çözünürlüğü 32x32 piksel olduğundan, $M\zeta_x$ ve $M\zeta_y$ sabit 32 değeriyle tanımlanmıştır (Jocher, 2021). Giriş çözünürlüğü için en yüksek çözünürlük ise 3840x2160 pikseldir. Bunun yanı sıra, eşitliklerdeki m katsayısı, GOH değerinin normalize edilmiş giriş çözünürlüğündeki (α) artış doğrultusunda hesaplanan katsayısını ifade etmektedir. Diğer taraftan, f katsayısı, FPS/Watt performans metriğinin normalize edilmiş giriş çözünürlüğüne (α) bağlı olarak belirlenen katsayı değeridir. Bu iki katsayının çarpımı sonucunda RSHAY parametresi hesaplanmaktadır. FPS/Watt değeri için en yüksek değer 25 olarak belirlenmiştir.

Giriş çözünürlüğünün artırılması, uç donanımın sınırlı işlem gücünün daha yoğun şekilde kullanılmasını sağlamakta ve model performansı üzerinde önemli bir etkiye bulunmaktadır. Aynı donanım üzerinde artan giriş çözünürlüğü, modelin doğruluk ve hız dengesi açısından değerlendirilmesine olanak tanırken, aynı çözünürlük değerleriyle farklı donanımlarda yapılan testler, cihazların göreceli performanslarının adil bir şekilde kıyaslanmasını mümkün kılmaktadır. Bu bağlamda, RSHAY puanı hem modellerin hem de uç donanımların karşılaştırmalı analizinde bütüncül bir yaklaşım sunmaktadır.

Uç cihazlarda obje tespit modellerinin çalıştırılabilmesi için modeller, Open Neural Network Exchange (ONNX) formatına dönüştürülmüştür. Bu format, Jetson ailesine ait donanımlarda yapılan analizlerin GPU belleği kullanılarak

gerçekleştirilmesini sağlamıştır. ONNX hem derin öğrenme hem de geleneksel makine öğrenmesi modelleri için bir dosya formatı olarak geniş bir kullanım alanı sunmaktadır (Jin ve diğ., 2020). ONNX, farklı yapay zeka çerçeveleri (örneğin, PyTorch, TensorFlow, Keras vb.) için ortak bir ara gösterim sağlamakta, hesaplamaya izin veren grafik modeli, operatör kümesi ve standart veri türleri tanımlamaktadır. Bu özelliği sayesinde, farklı çerçevelerde geliştirilen modellerin birlikte çalışabilirliğini artırmakta ve platformlar arası taşınabilirlik sağlamaktadır. ONNX formatındaki modeller, yalnızca görselleştirilebilir olmalarıyla kalmayıp, aynı zamanda donanım üzerinde çalıştırılabilir nitelikte oldukları için geniş bir uygulama alanına sahiptir.

Tez çalışmasında, farklı çerçevelerden elde edilen modeller, ONNX formatında birleştirilerek doğru ve tarafsız bir karşılaştırma yapılması sağlanmıştır. Bu yaklaşım, modellerin uç cihazlarda tutarlı bir şekilde değerlendirilmesine ve performanslarının standart bir ortamda analiz edilmesine olanak tanımıştır. Böylelikle, model performansı üzerinde çerçeve bağımsız bir değerlendirme yapılmış ve uç donanımlar arasında daha kapsamlı bir karşılaştırma gerçekleştirilmiştir. Bununla birlikte Rockchip tarafından üretilen RK3588 işlemcisi NPU donanımı kullandığı için ONNX formatının RKNN formatına çevrilmesi gerekmektedir. Rockchip tarafından sağlanan açık kaynaklı kod dizinleri (RKNN-Toolkit2 ve rknpu2) ile modellerin tamamı için tüm çözünürlük değerleri RKNN formatına çevrilmiş ve donanım üzerinde çalıştırılarak ölçüm alınmıştır. RKNN dosya formatının donanım için optimizasyon içerdiği ve bu optimizasyon yöntemlerinin modelin performansını değiştirdiği unutulmamalıdır. ONNX formatında ise donanıma özel optimizasyonlar yapılmamıştır.

4.3.1. Obje tespit modelleri için son işlem aşamasının yapay zeka modeline entegrasyonu

YOLO mimarisi kullanılarak oluşturulan obje tespit modelleri, giriş verisi olarak belirli çözünürlüğe sahip bir görüntü karesiyle beslenir ve çıkış olarak tahmin edilen sınırlayıcı kutuların ve sınıf olasılıklarının yer aldığı bir tensör üretir. Bu tensör, 640x640 piksel giriş çözünürlüğüne sahip bir model için [1, 8400, 84] boyutundadır. Giriş çözünürlüğüne göre tensörün ikinci elemanının sayısı (8400), sınıf sayısına göre de üçüncü elemanı (84) değişmektedir.


Üç boyutlu tensördeki ilk bileşen, tensörün boyutunda yer alan parti boyutu (batch size) değeridir ve yukarıda verilen örnekte 1'dir. Parti boyutu, bir eğitim veya tahmin

adımında modele verilen görüntü sayısını ifade eder. Bu çalışmada parti boyutu 1 olarak alınmıştır ve modelin her bir tahmin adımında yalnızca bir giriş görüntüsünü işlediğini gösterir. Eğitim süreçlerinde, parti boyutu değeri artırılarak birden fazla görüntü paralel olarak işlenebilir. Ancak tez çalışması kapsamında her tahmin ayrı ayrı değerlendirildiği için 1 olarak sabitlenmiştir.

İkinci bileşen, tahmin edilen çerçeve sayısını ifade etmektedir. YOLO mimarisi, giriş görüntüsünü belirli bir ızgara boyutunda (örneğin, $S \times S$) böler ve bu ızgaranın her bir hücresinde tahminler yapar. Ayrıca, her hücrede birden fazla sınır kutusu tahmini yapılır. Tahmin edilen toplam sınır kutusu sayısı, bu iki bileşenin çarpımı ile hesaplanır. Bu örnekte, 8400 sınır kutusu tahmini yapılmıştır.

Üçüncü bileşen, (84), her bir tahmin edilen çerçeveye ait bilgileri içerir. Bu bileşen koordinat bilgileri ve sınıf olasılıkları olmak üzere iki ana kategoriye ayrılmaktadır. Koordinat bilgileri, tahmin edilen sınır kutunun merkezinin (x, y) koordinatlarını, kutunun boyutunu genişlik (w) ve yükseklik (h) olarak tanımlamaktadır. Bu değerler piksel cinsinden ifade edilmektedir. Sınıf olasılıkları ise her bir sınıf için, sınır kutusunun o sınıfa ait olma olasılığını temsil eden değerlerdir. Bu örnekte, modelin 80 sınıfı tespit edebildiği varsayıldığından, bu olasılıklar 80 boyutlu bir vektör olarak temsil edilir.

Bu bilgiler, her tahmin edilen sınır kutusu için detaylı bir tahmin sunar ve modelin çıktısı tensörünün temel yapısını oluşturur. YOLO mimarisi, giriş çözünürlüğüne sahip bir görüntü karesini alır ve bu görüntüdeki nesneleri tahmin etmek için ızgara tabanlı bir yöntem kullanır. Çıkış tensöründe, her bir tahmin edilen çerçeve, koordinatlar, güven skorları ve sınıf olasılıkları ile ayrıntılı bir şekilde tanımlanır. Tahmin edilen kutuların bazılarının aynı objeyi niteleyebileceği unutulmamalıdır. Bu sebeple son işlem algoritmaları modelin çıkış tensöründeki verilere uygulanarak sadeleştirilir ve kutuların çizilmesi sağlanır. Bu işlemler son işlem bloğu olarak adlandırılmaktadır. Şekil 4.6, son işlem bloğunu ve modelin çıkarım sonrası görselleştirilmesi için geçen adımları göstermektedir.



Şekil 4.6. NMS algoritmasının son işlem fonksiyonları


Modelin çıkarım yapması için uç cihazın derin öğrenme algoritmalarını hızlı bir şekilde hesaplayabildiği GPU veya NPU birimi kullanılmaktadır. Uç cihazlarda hesaplama hızını hızlandıran bu donanımların en verimli şekilde kullanılması performansı doğrudan etkilemektedir. Buna karşın, modellerin üretmiş olduğu sonuç tensörünün son işlem bloğundan geçirilmesi CPU üzerinde yapılmaktadır ve bu yöntemin çıkarım sürelerini olumsuz etkilediği görülmüştür. Bu etkinin en aza indirilmesi için son işlem bloğundaki adımların tamamın ONNX modeline eklenmiş ve böylece modele ait tüm işlemlerin derin öğrenme algoritması hızlandırıcı donanımlara (GPU, NPU) aktarılması sağlanmıştır. Jetson ailesindeki uç cihazlarda yeni oluşan modellerle birlikte farklı çözünürlük değerlerinde performans ölçümleri alınmıştır.

YOLOv10 mimarisi, geleneksel NMS algoritmasını kullanmadan çalışan bir obje tespit modeli geliştirmek için son işlem bloğunda kullanılmak üzere DAS yöntemini önermiştir (Husaain ve diğ., 2024). Geleneksel NMS algoritması, aynı nesneye ait birden fazla yüksek güven skoruna sahip sınır kutusunun üretilmesi durumunda, bu kutular arasından en yüksek güven skoruna sahip olanını seçer ve diğerlerini belirli bir IoU eşik

değeriyle bastırmaktadır. Ancak, bu süreç hem ek hesaplama maliyeti gerektirir hem de bazı durumlarda değerli tahminlerin kaybına neden olabilir. DAS hem eğitim hem de çıkarım süreçlerinde doğrudan modelin tahminlerine entegre edilmiş bir şekilde çalışır. Model, tahmin edilen sınır kutuları ile gerçek kutular arasında bir optimizasyon süreci gerçekleştirir.

YOLOv10, bu yenilikle, özellikle gerçek zamanlı uygulamalarda daha hızlı ve daha doğru nesne tespiti gereksinimlerini karşılamak üzere tasarlanmıştır. DAS hem algoritmik yenilik hem de uygulama kolaylığı açısından modern nesne tespit modelleri için önemli bir adım olarak kabul edilmektedir. Tez çalışması kapsamında, YOLOv10 modelinin içerisinde bulunan yeni son işlem bloğu modelden ayrıştırılarak test için eğitilen diğer modellere eklenmiş ve performansları kayıt altına alınmıştır.


Şekil 4.7, modelin eklenti bulunmayan temel hali ile birlikte NMS ve DAS algoritmalarının entegrasyonu sonrası ONNX formatında görselleştirilmiş blok yapılarını sunmaktadır. Bu şekil, modelin eklentiler öncesi ve sonrası mimari değişimlerini karşılaştırmalı olarak incelemeye olanak tanımaktadır.



Şekil 4.7. Soldan sağa doğru: temel model, NMS ve DAS eklenmiş hali

4.3.2. Uygulama sonuçları

Objelerin tespiti için olumsuz hava koşullarından (sis, yetersiz ışık vb.) en az etkilenen görüntüleme yöntemi olan termal görüntüler ile eğitilen obje tespit modellerinin sınırlı kaynaklara sahip uç cihaz performansları incelenmiş ve verimlilik artırıcı iyileştirmeler yapılmıştır. Böylece, modellerin tespit süresinin hızlandırılması, enerji verimliliğinin artırılması ve gerçek zamanlı uygulamalar için kullanılabilir hale getirilmesi sağlanmıştır. Termal veriler ile eğitilen YOLOX, Gold-YOLO, YOLOv8, YOLOv9, YOLOv10 obje tespit modellerinden 224x224, 320x320, 512x512, 640x640 piksel giriş çözünürlüğüne sahip ONNX formatında GPU üzerinde çalışacak 20 adet model türetilmiştir. Ayrıca her model ve çözünürlükte NMS algoritmasının ve DAS yönteminin modele eklendiği ve GPU üzerinde çalıştırıldığı modeller de türetilerek toplam model sayısı 60 olarak belirlenmiştir. Test için oluşturulan bu yapı Şekil 4.8’de şematize edilmiştir. Modellerin her biri Jetson ailesine ait Jetson Nano, Jetson NX, Jetson Orin Nano ve Jetson Orin NX uç cihazlarda ONNX formatında GPU üzerinde çıkarım yapacak şekilde çalıştırılmıştır. Her model için FPS, Watt değerleri kaydedilmiştir. Son işlemin modele eklenmiş olduğu “postNMS” ve “postDAS” modelleri, Rockchip RK3588 işlemcisinde bulunan NPU donanımı tarafından desteklenmediği için modellerin son işlem fonksiyonu eklenmemiş halleri test edilmiştir. Ölçüm sonuçları Çizelge 4.3-4.25’de verilmiştir.



Şekil 4.8. Çalışmada kullanılan modellerin oluşturulması

Çizelge 4.3. Jetson Orin Nano uç cihazı için YOLOX modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NANO	YOLOX	NoPost.	224x224	7,6	61,37	54,5	8,1	440	82,52
			320x320	7,79	48,3	60,3	6,2	374	91,53
			512x512	8,55	35,83	67,2	4,2	282	96,40
			640x640	8,93	26,45	70,3	3,0	208	82,88
		PostNMS	224x224	7,6	59,51	54,5	7,8	427	80,02
			320x320	8,17	55,68	60,3	6,8	411	100,61
			512x512	9,12	48,83	67,2	5,4	360	123,17
			640x640	9,5	33,89	70,3	3,6	251	99,82
		PostDAS	224x224	7,6	63,63	54,5	8,4	456	85,56
			320x320	7,98	58,24	60,3	7,3	440	107,74
			512x512	9,5	53,38	67,2	5,6	378	129,26
			640x640	9,69	39,8	70,3	4,1	289	114,92

Çizelge 4.4. Jetson Orin Nano uç cihazı için Gold-YOLO modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NANO	Gold-YOLO	NoPost.	224x224	8,17	41,93	62,5	5,1	321	60,15
			320x320	8,36	41,41	73,5	5,0	364	89,13
			512x512	8,93	29,35	83,6	3,3	275	94,06
			640x640	9,12	21,39	85,2	2,3	200	79,53
		PostNMS	224x224	8,17	47,18	62,5	5,8	361	67,68
			320x320	8,36	44,72	73,5	5,3	393	96,26
			512x512	9,12	37,89	83,6	4,2	347	118,90
			640x640	9,69	28,43	85,2	2,9	250	99,49
		PostDAS	224x224	8,17	47,41	62,5	5,8	363	68,01
			320x320	8,55	45,2	73,5	5,3	389	95,13
			512x512	9,12	39,75	83,6	4,4	364	124,74
			640x640	9,69	30	85,2	3,1	264	104,99

Çizelge 4.5. Jetson Orin Nano uç cihazı için YOLOv8 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NANO	YOLOv8	NoPost.	224x224	7,98	58,48	55,7	7,3	408	76,54
			320x320	8,17	49,55	76,3	6,1	463	113,29
			512x512	8,74	33,1	85,2	3,8	323	110,46
			640x640	9,31	22,85	87,7	2,5	215	85,67
		PostNMS	224x224	8,17	62,89	55,7	7,7	429	80,40
			320x320	8,36	56,76	76,3	6,8	518	126,83
			512x512	9,31	43,11	85,2	4,6	395	135,06
			640x640	9,88	30,95	87,7	3,1	275	109,34
		PostDAS	224x224	8,17	68,12	55,7	8,3	464	87,09
			320x320	9,5	60,43	76,3	6,4	485	118,83
			512x512	9,69	45,89	85,2	4,7	403	138,13
			640x640	9,88	32,89	87,7	3,3	292	116,20

Çizelge 4.6. Jetson Orin Nano uç cihazı için YOLOv9 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NANO	YOLOv9	NoPost.	224x224	7,22	32,1	61,4	4,4	273	51,19
			320x320	7,6	29,8	75,2	3,9	295	72,19
			512x512	8,17	20,35	85,1	2,5	212	72,56
			640x640	8,36	16,52	87,6	2,0	173	68,90
		PostNMS	224x224	7,41	39,2	61,4	5,3	325	60,91
			320x320	7,6	37,8	75,2	5,0	374	91,57
			512x512	8,36	28	85,1	3,3	285	97,57
			640x640	8,93	26,22	87,6	2,9	257	102,37
		PostDAS	224x224	7,6	32,4	61,4	4,3	262	49,08
			320x320	7,79	31,6	75,2	4,1	305	74,68
			512x512	8,36	30,24	85,1	3,6	308	105,38
			640x640	9,12	28	87,6	3,1	269	107,04

Çizelge 4.7. Jetson Orin Nano uç cihazı için YOLOv10 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NANO	YOLOv10	NoPost.	224x224	7,79	54,88	63,5	7,0	447	83,89
			320x320	8,17	44,61	75,4	5,5	412	100,79
			512x512	8,74	27	84,5	3,1	261	89,36
			640x640	9,12	19,16	86,2	2,1	181	72,08
		PostNMS	224x224	7,6	39,77	63,5	5,2	332	62,31
			320x320	7,98	34,45	75,4	4,3	326	79,69
			512x512	8,55	22,25	84,5	2,6	220	75,28
			640x640	8,93	18,53	86,2	2,1	179	71,19
		PostDAS	224x224	7,79	59,47	63,5	7,6	485	90,90
			320x320	8,17	53,83	75,4	6,6	497	121,63
			512x512	9,12	41,61	84,5	4,6	386	131,98
			640x640	9,88	29,95	86,2	3,0	261	104,00

Çizelge 4.8. Jetson Orin NX uç cihazı için YOLOX modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NX	YOLOX	NoPost.	224x224	12,54	78,7	54,5	6,3	342	64,14
			320x320	13,3	64,2	60,3	4,8	291	71,26
			512x512	14,44	49,8	67,2	3,4	232	79,34
			640x640	15,2	37,7	70,3	2,5	174	69,40
		PostNMS	224x224	12,73	81,6	54,5	6,4	349	65,51
			320x320	13,3	72,7	60,3	5,5	330	80,70
			512x512	15,2	66,2	67,2	4,4	293	100,19
			640x640	15,96	47,8	70,3	3,0	211	83,80
		PostDAS	224x224	12,54	83,2	54,5	6,6	362	67,80
			320x320	13,3	77,6	60,3	5,8	352	86,14
			512x512	15,2	71,3	67,2	4,7	315	107,91
			640x640	16,15	56,2	70,3	3,5	245	97,37

Çizelge 4.9. Jetson Orin NX uç cihazı için Gold-YOLO modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NX	Gold-YOLO	NoPost.	224x224	13,49	61,75	62,5	4,6	286	53,65
			320x320	13,87	55,8	73,5	4,0	296	72,39
			512x512	14,44	41,6	83,6	2,9	241	82,45
			640x640	15,2	30,4	85,2	2,0	170	67,82
		PostNMS	224x224	13,49	70,2	62,5	5,2	325	60,99
			320x320	13,87	63,2	73,5	4,6	335	81,99
			512x512	15,2	52,1	83,6	3,4	287	98,09
			640x640	16,15	40,4	85,2	2,5	213	84,83
		PostDAS	224x224	13,68	71	62,5	5,2	324	60,83
			320x320	14,06	62,5	73,5	4,4	327	79,99
			512x512	15,39	56,3	83,6	3,7	306	104,69
			640x640	16,34	42,7	85,2	2,6	223	88,62

Çizelge 4.10. Jetson Orin NX uç cihazı için YOLOv8 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NX	YOLOv8	NoPost.	224x224	13,3	81,5	55,7	6,1	341	64,00
			320x320	13,87	69	76,3	5,0	380	92,93
			512x512	14,63	45,5	85,2	3,1	265	90,71
			640x640	15,2	31,5	87,7	2,1	182	72,34
		PostNMS	224x224	13,3	84,5	55,7	6,4	354	66,36
			320x320	14,06	76,3	76,3	5,4	414	101,37
			512x512	15,39	58,5	85,2	3,8	324	110,87
			640x640	16,15	43,2	87,7	2,7	235	93,37
		PostDAS	224x224	13,3	88	55,7	6,6	369	69,11
			320x320	14,06	80,5	76,3	5,7	437	106,95
			512x512	15,58	62,1	85,2	4,0	340	116,25
			640x640	16,34	46,9	87,7	2,9	252	100,19

Çizelge 4.11. Jetson Orin NX uç cihazı için YOLOv9 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NX	YOLOv9	NoPost.	224x224	12,3	50,1	61,4	4,1	250	46,90
			320x320	12,73	44,5	75,2	3,5	263	64,36
			512x512	13,68	33,4	85,1	2,4	208	71,13
			640x640	14,25	26,7	87,6	1,9	164	65,33
		PostNMS	224x224	12,5	51,2	61,4	4,1	251	47,16
			320x320	12,73	48,5	75,2	3,8	287	70,14
			512x512	13,49	42,2	85,1	3,1	266	91,13
			640x640	13,87	39,7	87,6	2,9	251	99,80
		PostDAS	224x224	12,51	53,2	61,4	4,3	261	48,96
			320x320	12,73	51	75,2	4,0	301	73,76
			512x512	14,06	47,8	85,1	3,4	289	99,04
			640x640	15,2	42,8	87,6	2,8	247	98,17

Çizelge 4.12. Jetson Orin NX uç cihazı için YOLOv10 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON ORIN NX	YOLOv10	NoPost.	224x224	12,92	75	63,5	5,8	369	69,12
			320x320	13,49	61,5	75,4	4,6	344	84,16
			512x512	14,44	41	84,5	2,8	240	82,13
			640x640	15,01	27,2	86,2	1,8	156	62,17
		PostNMS	224x224	12,54	50,3	63,5	4,0	255	47,76
			320x320	13,3	46,5	75,4	3,5	264	64,54
			512x512	14,06	31,1	84,5	2,2	187	63,98
			640x640	14,82	25,5	86,2	1,7	148	59,03
		PostDAS	224x224	13,1	76,5	63,5	5,8	371	69,53
			320x320	13,87	72	75,4	5,2	391	95,83
			512x512	15,58	56,8	84,5	3,6	308	105,46
			640x640	16,34	44,2	86,2	2,7	233	92,81

Çizelge 4.13. Jetson Nano uç cihazı için YOLOX modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON NANO	YOLOX	NoPost.	224x224	5,5	27,02	54,5	4,9	268	50,21
			320x320	6,5	22,18	60,3	3,4	206	50,38
			512x512	6,9	11,37	67,2	1,6	111	37,91
			640x640	7,1	7,67	70,3	1,1	76	30,23
		PostNMS	224x224	5,6	25,86	54,5	4,6	252	47,19
			320x320	7	21,3	60,3	3,0	183	44,92
			512x512	7,2	10,9	67,2	1,5	102	34,83
			640x640	7,5	7,85	70,3	1,0	74	29,29
		PostDAS	224x224	5,35	27,92	54,5	5,2	284	53,33
			320x320	6,5	20,37	60,3	3,1	189	46,26
			512x512	7,2	9,2	67,2	1,3	86	29,39
			640x640	7,25	7,7	70,3	1,1	75	29,72

Çizelge 4.14. Jetson Nano uç cihazı için Gold-YOLO modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON NANO	Gold-YOLO	NoPost.	224x224	6,6	20,72	62,5	3,1	196	36,79
			320x320	7	14,78	73,5	2,1	155	37,99
			512x512	7,5	6,92	83,6	0,9	77	26,41
			640x640	7,9	4,37	85,2	0,6	47	18,76
		PostNMS	224x224	6,5	18,2	62,5	2,8	175	32,82
			320x320	6,75	12,3	73,5	1,8	134	32,79
			512x512	7	6,58	83,6	0,9	79	26,90
			640x640	7,3	4,55	85,2	0,6	53	21,14
		PostDAS	224x224	6,6	19,64	62,5	3,0	186	34,87
			320x320	6,9	14,14	73,5	2,0	151	36,88
			512x512	7,05	6,93	83,6	1,0	82	28,13
			640x640	7,5	4,22	85,2	0,6	48	19,08

Çizelge 4.15. Jetson Nano uç cihazı için YOLOv8 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON NANO	YOLOv8	NoPost.	224x224	6,3	27,84	55,7	4,4	246	46,16
			320x320	6,5	17,48	76,3	2,7	205	50,24
			512x512	6,75	9,2	85,2	1,4	116	39,75
			640x640	7,15	5,95	87,7	0,8	73	29,05
		PostNMS	224x224	6,2	27,13	55,7	4,4	244	45,70
			320x320	6,6	16,04	76,3	2,4	185	45,40
			512x512	6,75	8,53	85,2	1,3	108	36,86
			640x640	7,25	5,93	87,7	0,8	72	28,55
		PostDAS	224x224	6,45	28,46	55,7	4,4	246	46,09
			320x320	6,95	15,8	76,3	2,3	173	42,47
			512x512	6,9	8,36	85,2	1,2	103	35,34
			640x640	7,1	5,68	87,7	0,8	70	27,92

Çizelge 4.16. Jetson Nano uç cihazı için YOLOv9 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON NANO	YOLOv9	NoPost.	224x224	5	15,8	61,4	3,2	194	36,38
			320x320	5,5	13,6	75,2	2,5	186	45,53
			512x512	6,25	8,54	85,1	1,4	116	39,81
			640x640	6,75	5,72	87,6	0,8	74	29,55
		PostNMS	224x224	4,9	16,1	61,4	3,3	202	37,83
			320x320	5	13,74	75,2	2,7	207	50,59
			512x512	6,25	9,73	85,1	1,6	132	45,35
			640x640	6,65	6,81	87,6	1,0	90	35,70
		PostDAS	224x224	4,85	17,6	61,4	3,6	223	41,78
			320x320	5	16,24	75,2	3,2	244	59,80
			512x512	6,65	14	85,1	2,1	179	61,33
			640x640	7,1	8,95	87,6	1,3	110	43,95

Çizelge 4.17. Jetson Nano uç cihazı için YOLOv10 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON NANO	YOLOv10	NoPost.	224x224	5,5	22,9	63,5	4,2	264	49,58
			320x320	5,8	13,32	75,4	2,3	173	42,39
			512x512	6,5	6,7	84,5	1,0	87	29,82
			640x640	7,05	4,45	86,2	0,6	54	21,66
		PostNMS	224x224	5	16,36	63,5	3,3	208	38,96
			320x320	5,5	9,84	75,4	1,8	135	33,03
			512x512	6,5	4,9	84,5	0,8	64	21,81
			640x640	7,05	3,55	86,2	0,5	43	17,28
		PostDAS	224x224	5,5	25,32	63,5	4,6	292	54,82
			320x320	6,35	13,25	75,4	2,1	157	38,52
			512x512	6,85	6,76	84,5	1,0	83	28,55
			640x640	7	4,8	86,2	0,7	59	23,53

Çizelge 4.18. Jetson Xavier NX uç cihazı için YOLOX modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON XAVIER NX	YOLOX	NoPost.	224x224	8,88	56,48	54,5	6,4	347	65,00
			320x320	9,6	44,3	60,3	4,6	278	68,13
			512x512	10,68	30,16	67,2	2,8	190	64,96
			640x640	11,76	22,36	70,3	1,9	134	53,20
		PostNMS	224x224	9	62,18	54,5	6,9	377	70,61
			320x320	10,08	55,68	60,3	5,5	333	81,55
			512x512	12	46,77	67,2	3,9	262	89,66
			640x640	13,2	38,22	70,3	2,9	204	81,02
		PostDAS	224x224	9,12	64,15	54,5	7,0	383	71,88
			320x320	9,96	58,34	60,3	5,9	353	86,47
			512x512	12	52,88	67,2	4,4	296	101,37
			640x640	13,2	42,11	70,3	3,2	224	89,26

Çizelge 4.19. Jetson Xavier NX uç cihazı için Gold-YOLO modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON XAVIER NX	Gold-YOLO	NoPost.	224x224	9,6	38,82	62,5	4,0	253	47,39
			320x320	10,2	36,17	73,5	3,5	261	63,81
			512x512	10,56	23,16	83,6	2,2	183	62,77
			640x640	11,76	18	85,2	1,5	130	51,90
		PostNMS	224x224	9,96	46,75	62,5	4,7	293	55,01
			320x320	10,8	45,9	73,5	4,3	312	76,48
			512x512	11,76	33,28	83,6	2,8	237	80,99
			640x640	13,2	26,56	85,2	2,0	171	68,23
		PostDAS	224x224	10,44	50,21	62,5	4,8	301	56,36
			320x320	10,8	47,14	73,5	4,4	321	78,54
			512x512	11,76	36,21	83,6	3,1	257	88,12
			640x640	13,32	28,2	85,2	2,1	180	71,79

Çizelge 4.20. Jetson Xavier NX uç cihazı için YOLOv8 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON XAVIER NX	YOLOv8	NoPost.	224x224	9,6	48,47	55,7	5,0	281	52,73
			320x320	10,56	43,08	76,3	4,1	311	76,21
			512x512	11,28	26,66	85,2	2,4	201	68,93
			640x640	12	17,73	87,7	1,5	130	51,57
		PostNMS	224x224	9,6	61,45	55,7	6,4	357	66,86
			320x320	10,8	53	76,3	4,9	374	91,67
			512x512	12	34,18	85,2	2,8	243	83,08
			640x640	13,2	24,68	87,7	1,9	164	65,26
		PostDAS	224x224	9,84	67,8	55,7	6,9	384	71,97
			320x320	11,16	59,22	76,3	5,3	405	99,13
			512x512	12,6	39,31	85,2	3,1	266	90,99
			640x640	13,32	26,86	87,7	2,0	177	70,39

Çizelge 4.21. Jetson Xavier NX uç cihazı için YOLOv9 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON XAVIER NX	YOLOv9	NoPost.	224x224	8,88	35,4	61,4	4,0	245	45,90
			320x320	9,12	30,45	75,2	3,3	251	61,47
			512x512	9,6	21,52	85,1	2,2	191	65,30
			640x640	10,08	16,8	87,6	1,7	146	58,11
		PostNMS	224x224	9	37,1	61,4	4,1	253	47,46
			320x320	9,24	35,7	75,2	3,9	291	71,13
			512x512	10,2	31,13	85,1	3,1	260	88,91
			640x640	11,64	29,14	87,6	2,5	219	87,28
		PostDAS	224x224	8,88	38,2	61,4	4,3	264	49,53
			320x320	9,12	37,77	75,2	4,1	311	76,25
			512x512	10,8	35,75	85,1	3,3	282	96,43
			640x640	12	33,5	87,6	2,8	245	97,33

Çizelge 4.22. Jetson Xavier NX uç cihazı için YOLOv10 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
JETSON XAVIER NX	YOLOv10	NoPost.	224x224	9,84	47,4	63,5	4,8	306	57,36
			320x320	10,44	41,37	75,4	4,0	299	73,15
			512x512	11,4	24,31	84,5	2,1	180	61,69
			640x640	12	16,52	86,2	1,4	119	47,23
		PostNMS	224x224	9,24	37,21	63,5	4,0	256	47,95
			320x320	9,96	32,22	75,4	3,2	244	59,72
			512x512	11,04	19,17	84,5	1,7	147	50,23
			640x640	11,4	15,9	86,2	1,4	120	47,85
		PostDAS	224x224	9,96	59	63,5	5,9	376	70,53
			320x320	10,92	51,67	75,4	4,7	357	87,35
			512x512	12,36	35,25	84,5	2,9	241	82,50
			640x640	13,2	16,3	86,2	1,2	106	42,37

Çizelge 4.23. Rockchip RK3588 uç cihazı için YOLOX modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
ROCKCHIP RK3588	YOLOX	NoPost.	224x224	9,5	95,36	54,5	10,5	547	102,58
			320x320	9,6	59,75	60,3	6,2	375	91,43
			512x512	14,5	29,03	67,2	2,0	135	45,92
			640x640	15,1	19,7	70,3	1,3	92	36,50


Çizelge 4.24. Rockchip RK3588 uç cihazı için Gold-YOLO modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
ROCKCHIP RK3588	Gold-YOLO	NoPost.	224x224	9,7	81,92	62,5	8,4	528	98,19
			320x320	9,8	59,18	73,5	6,0	444	108,67
			512x512	14,8	22,86	83,6	1,5	129	43,89
			640x640	15,4	15,43	85,2	1,0	85	33,98


Çizelge 4.25. Rockchip RK3588 uç cihazı için YOLOv8 modeli değerlendirme tablosu

Donanım Adı	Model Adı	Son İşlem	Çözünürlük	Güç	FPS	GOH	$\frac{FPS}{Watt}$	RSH	RSHAY
ROCKCHIP RK3588	YOLOv8	NoPost.	224x224	9,5	84,02	55,7	8,8	493	92,37
			320x320	9,5	47,04	76,3	5,0	378	92,50
			512x512	14,7	24,1	85,2	1,6	140	47,82
			640x640	14,5	13,8	87,7	1,0	83	33,22


Çizelge 4.3-4.25'te yer alan sonuçlar üç farklı yaklaşımla analiz edilmelidir. Bu yöntemlerden ilki, her uç cihazın ve obje tespit modelinin kendi içinde değerlendirildiği ve modele eklenen son işlem fonksiyonlarının etkisinin analiz edildiği FPS/Watt değerinin incelendiği yöntemdir. Böylece modelde yapılan değişikliğin performansa olan etkisi analiz edilebilmektedir. FPS/Watt değerindeki artış modelin daha verimli çalıştığını göstermektedir. İkicisi yöntem ise her bir uç cihazın kendi içinde incelendiği ve aynı giriş çözünürlüğüne sahip modellerin karşılaştırıldığı analiz yöntemidir. Bu yaklaşımda RSH puanı karşılaştırma metriği olarak kullanılmaktadır. Analiz edilecek uç cihaz belirlendikten sonra, aynı çözünürlükteki en yüksek RSH puanına sahip model ve son işlem yöntemi en verimli sonucu vermektedir. Üçüncü değerlendirme yöntemi, her bir uç cihaz içerisindeki en verimli modelin tespitini hedefler. Bu analiz yöntemi, RSHAY parametresine göre yapılmaktadır. Bu parametre sayesinde, her uç cihaz için en verimli model belirlendikten sonra, cihazlar arasında da RSHAY puan karşılaştırması yapılarak en verimli uç cihaz-obje tespit modeli çiftinin belirlenmesi sağlanır. Şekil 4.9-4.13'de test edilen tüm uç cihazlar için RSHAY değerlerini içeren grafikler gösterilmektedir.




Şekil 4.9: Jetson Orin Nano için RSHAY puan karşılaştırması




Şekil 4.10: Jetson Orin NX için RSHAY puan karşılaştırması



Şekil 4.11: Jetson Nano için RSHAY puan karşılaştırması



Şekil 4.12: Jetson Xavier NX için RSHAY puan karşılaştırması



Şekil 4.13: Rockchip RK3588 için RSHAY puan karşılaştırması

Jetson Orin Nano uç cihazı için Çizelge 4.3-4.7 incelendiğinde ilk karşılaştırma metriği olan FPS/Watt puanına göre tüm çözünürlük değerlerinde modele eklenen son işlem fonksiyonlarının performansı olumlu yönde etkilediği görülmüştür. NMS algoritmasının Gold-YOLO 320x320, YOLOv8 320x320, YOLOv9 224x224 ile 320x320 modellerinde daha verimli, DAS algoritmasının ise diğer tüm model ve çözünürlüklerde daha verimli olduğu tespit edilmiştir. Bununla birlikte ikinci karşılaştırma metriği olan RSH parametresi incelendiğinde giriş çözünürlüğüne göre 224x224 için YOLOv10-DAS, 320x320 için YOLOv8-NMS, 512x512 için YOLOv8-DAS, 640x640 için YOLOv8-DAS tercih edilmesi gereken obje tespit modelleri olmuştur. Üçüncü değerlendirme metriği olan RSHAY parametresine göre ise en verimli obje tespit modeli, giriş çözünürlüğü 512x512 piksel olan YOLOv8-DAS modeli olmuştur.

Jetson Orin NX uç cihazı için Çizelge 4.8-4.12 incelendiğinde ilk karşılaştırma metriği olan FPS/Watt puanına göre tüm çözünürlük değerlerinde modele eklenen son işlem fonksiyonlarının performansı olumlu yönde etkilediği görülmüştür. NMS algoritmasının Gold-YOLO 224x224 ve 320x320, YOLOv9 640x640 modellerinde daha verimli, DAS algoritmasının ise diğer tüm model ve çözünürlüklerde daha verimli olduğu tespit edilmiştir. Bununla birlikte ikinci karşılaştırma metriği olan RSH parametresi incelendiğinde giriş çözünürlüğüne göre 224x224 için YOLOv10-DAS, 320x320 için YOLOv8-DAS, 512x512 için YOLOv8-DAS, 640x640 için YOLOv8-DAS tercih edilmesi gereken obje tespit modelleri olmuştur. Üçüncü değerlendirme metriği olan RSHAY parametresine göre ise en verimli obje tespit modeli, giriş çözünürlüğü 512x512 piksel olan YOLOv8-DAS modeli olmuştur.

Jetson Nano uç cihazı için Çizelge 4.13-4.17 incelendiğinde ilk karşılaştırma metriği olan FPS/Watt puanına göre DAS algoritmasının YOLOX 224x224, Gold-YOLO

512x512, YOLOv8 22x224, YOLOv9 tüm çözünürlükler, YOLOv10 22x224 ve 640x640 modelleri daha verimli olduğu, NMS algoritmasının ise verimliliği kötü etkilediği tespit edilmiştir. Jetson Nano'nun sınırlı GPU işlem kapasitesi, son işlem fonksiyonlarının modele dahil edilmesiyle güç tüketiminde artışa neden olmuş, buna karşın modellerin genelinde elde edilen FPS değerinin yetersiz kalması sonucunda genel verimlilikte bir düşüş gözlemlenmiştir. Bununla birlikte ikinci karşılaştırma metriği olan RSH parametresi incelendiğinde giriş çözünürlüğüne göre 224x224 için YOLOv10-DAS, 320x320 için YOLOv9-DAS, 512x512 için YOLOv9-DAS, 640x640 için YOLOv9-DAS tercih edilmesi gereken obje tespit modelleri olmuştur. Üçüncü değerlendirme metriği olan RSHAY parametresine göre ise en verimli obje tespit modeli, giriş çözünürlüğü 512x512 piksel olan YOLOv9-DAS modeli olmuştur.

Jetson Xavier NX uç cihazı için Çizelge 4.18-4.22 incelendiğinde ilk karşılaştırma metriği olan FPS/Watt puanına göre tüm çözünürlük değerlerinde modele eklenen son işlem fonksiyonlarının performansı olumlu yönde etkilediği görülmüştür. NMS algoritmasının YOLOv8 640x640, YOLOv10 640x640 modellerinde daha verimli, DAS algoritmasının ise diğer tüm model ve çözünürlüklerde daha verimli olduğu tespit edilmiştir. Bununla birlikte ikinci karşılaştırma metriği olan RSH parametresi incelendiğinde giriş çözünürlüğüne göre 224x224 için YOLOv8-DAS, 320x320 için YOLOv8-DAS, 512x512 için YOLOX-DAS, 640x640 için YOLOv9-DAS tercih edilmesi gereken obje tespit modelleri olmuştur. Üçüncü değerlendirme metriği olan RSHAY parametresine göre ise en verimli obje tespit modeli, giriş çözünürlüğü 512x512 piksel olan YOLOX-DAS modeli olmuştur.

Rockchip RK33588 uç cihazı için Çizelge 4.23-4.25 incelendiğinde son işlem fonksiyonlarının desteklenmemesinden dolayı NMS ve DAS algoritmalarının performansa olan etkisi FPS/Watt puanına göre ölçülememektedir. Bununla birlikte RSH parametresine göre giriş çözünürlüğü 224x224 için YOLOX, 320x320 için Gold-YOLO, 512x512 için YOLOv8, 640x640 için YOLOX tercih edilmesi gereken modeller olarak değerlendirilmektedir. Üçüncü değerlendirme metriği olan RSHAY parametresine göre ise en verimli obje tespit modeli, giriş çözünürlüğü 320x320 piksel olan Gold-YOLO modeli olmuştur.

Çizelge 4.26, her uç cihaz için hesaplanan en yüksek RSH puanına sahip modelleri ve FPS değerlerini göstermektedir.

Çizelge 4.26. Uç donanımların RSH parametresine göre değerlendirilmesi ve FPS değerleri

JETSON ORIN NANO				
Çözünürlük	Model Adı	Model Eklentisi	FPS	RSH
224x224	YOLOv10	PostDAS	59,47	485
320x320	YOLOv8	PostNMS	56,76	518
512x512	YOLOv8	PostDAS	45,89	403
640x640	YOLOv8	PostDAS	32,89	292
JETSON ORIN NX				
Çözünürlük	Model Adı	Model Eklentisi	FPS	RSH
224x224	YOLOv10	PostDAS	76,5	371
320x320	YOLOv8	PostDAS	80,5	437
512x512	YOLOv8	PostDAS	62,1	340
640x640	YOLOv8	PostDAS	46,9	252
JETSON NANO				
Çözünürlük	Model Adı	Model Eklentisi	FPS	RSH
224x224	YOLOv10	PostDAS	25,32	292
320x320	YOLOv9	PostDAS	16,24	244
512x512	YOLOv9	PostDAS	14,0	179
640x640	YOLOv9	PostDAS	8,95	110
JETSON XAVIER NX				
Çözünürlük	Model Adı	Model Eklentisi	FPS	RSH
224x224	YOLOv8	PostDAS	67,1	384
320x320	YOLOv8	PostDAS	59,22	405
512x512	YOLOX	PostDAS	52,88	296
640x640	YOLOv9	PostDAS	33,5	245
RK3588				
Çözünürlük	Model Adı	Model Eklentisi	FPS	RSH
224x224	YOLOX	NoPost.	95,36	547
320x320	Gold-YOLO	NoPost.	59,18	444
512x512	YOLOv8	NoPost.	24,1	140
640x640	YOLOX	NoPost.	70,3	92

Bu tez çalışması, gerçek zamanlı çalışan modellere odaklandığından, 24 FPS'in altındaki modeller değerlendirme kapsamı dışında bırakılmıştır. Bu doğrultuda, Jetson Nano donanımı yalnızca 224x224 piksel çözünürlüğe sahip YOLOv10 PostDAS modeliyle gerçek zamanlı kullanım için uygun bir seçenek sunmaktadır. Test edilen diğer çözünürlüklerdeki FPS değerinin 24'ün altında kaldığı saptanmıştır.

Çizelge 4.27, her donanım için RSHAY puanı kullanılarak yapılan karşılaştırma sonucunda belirlenen en iyi üç modeli göstermektedir.

Çizelge 4.27. Uç donanımların RSHAY parametresine göre en yüksek puan sıralaması

Donanım Adı	Model Adı	Çözünürlük	Model Eklenti	RSHAY
J. ORIN NANO	YOLOv8	512x512	PostDAS	138
J. ORIN NANO	YOLOv8	512x512	PostNMS	135
J. ORIN NANO	YOLOv10	512x512	PostDAS	131
J. ORIN NX	YOLOv8	512x512	PostDAS	116
J. ORIN NX	YOLOv8	512x512	PostNMS	111
J. ORIN NX	YOLOX	512x512	PostDAS	108
J. NANO	YOLOv9	512x512	PostDAS	61
J. NANO	YOLOv9	320x320	PostDAS	60
J. NANO	YOLOv10	224x224	PostDAS	55
J. XAVIER NX	YOLOX	512x512	PostDAS	101
J. XAVIER NX	YOLOv8	320x320	PostDAS	99
J. XAVIER NX	YOLOv9	640x640	PostDAS	97
RK3588	Gold-YOLO	320x320	NoPost.	109
RK3588	YOLOX	224x224	NoPost.	103
RK3588	Gold-YOLO	224x224	NoPost.	99

Tüm donanım ve modellerin ayrıntılı analizi sonucunda, en verimli uç donanım ve obje tespit modeli kombinasyonu olarak Jetson Orin Nano üzerinde çalışan YOLOv8 modeli belirlenmiştir. Bu model, 512x512 piksel çözünürlükte en yüksek performansı göstermiş ve PostDAS yöntemiyle desteklendiğinde 138 RSHAY puanına ulaşmıştır. Jetson Orin Nano üzerinde aynı çözünürlükte YOLOv8 modeli, PostNMS yöntemiyle 135 RSHAY puanına erişmiş, bu da PostDAS yönteminin modele sağladığı ek performans artışını ortaya koymuştur. Ayrıca, Jetson Orin Nano üzerinde YOLOv10 modeli, yine 512x512 çözünürlükte PostDAS yöntemiyle 131 RSHAY puanına ulaşarak, YOLOv8 modelinden sonra ikinci en iyi performansı sunan model olmuştur.

Jetson Orin NX donanımı incelendiğinde, en yüksek performansın YOLOv8 modeliyle elde edildiği görülmüştür. 512x512 piksel çözünürlükte PostDAS yöntemi kullanıldığında YOLOv8 modeli, 116 RSHAY puanına ulaşmıştır. Aynı model, PostNMS yöntemiyle 111 RSHAY puanına erişerek PostDAS yöntemine kıyasla daha düşük bir performans sergilemiştir. Jetson Orin NX üzerinde YOLOX modeli, yine PostDAS yöntemiyle desteklendiğinde 108 RSHAY puanına ulaşmış, ancak YOLOv8 modeline kıyasla daha düşük bir verimlilik göstermiştir. Bu sonuçlar, Jetson Orin NX donanımı üzerinde YOLOv8 modelinin en verimli seçenek olduğunu göstermektedir.

Jetson Nano donanımı ise genel olarak düşük performans sergilemiştir. En yüksek puan, 512x512 piksel çözünürlükte PostDAS yöntemiyle desteklenen YOLOv9 modeliyle 61 RSHAY olarak elde edilmiştir. Bununla birlikte, 320x320 piksel çözünürlükte yine PostDAS yöntemiyle desteklenen YOLOv9 modeli, 60 RSHAY puanı ile ikinci sırada yer almıştır. Üçüncü sırada ise PostDAS yöntemiyle kullanılan ve 224x224 giriş çözünürlüğüne sahip YOLOv10 modeli, 55 RSHAY puanı almıştır. Bu modeller arasında, yalnızca YOLOv10 modeli gerçek zamanlı çalışmayı sağlayabilmiştir. Diğer çözünürlüklerde ve modellerde elde edilen puanlar, gerçek zamanlı uygulamalar için yeterli olmamış ve Jetson Nano donanımının bu bağlamda sınırlı bir kullanım alanına sahip olduğu ortaya çıkmıştır. Özellikle yüksek çözünürlüklerde performansın daha da düştüğü gözlemlenmiş, bu da Jetson Nano'nun yoğun iş yükü gerektiren uygulamalar için uygun bir donanım olmadığını göstermiştir.

Jetson Xavier NX donanımı üzerinde yapılan değerlendirmelerde, en yüksek performans 512x512 piksel çözünürlükte PostDAS yöntemiyle desteklenen YOLOX modeliyle elde edilmiştir. Bu kombinasyon, 101 RSHAY puanına ulaşmıştır. Aynı donanımda YOLOv8 modeli, 320x320 çözünürlükte PostDAS yöntemiyle 99 RSHAY puanı almış ve ikinci sırada yer almıştır. Bu sonuçlar, Jetson Xavier NX'in orta düzey bir performans sağladığını göstermektedir.


RK3588 donanımı ise farklı bir performans profili sergilemiştir. En yüksek puan, 320x320 piksel çözünürlükte çalışan Gold-YOLO modeliyle 109 RSHAY olarak elde edilmiştir. Bu donanımda Gold-YOLO modeli, 224x224 çözünürlükte 99 RSHAY puanına ulaşarak düşük çözünürlüklerde de etkili bir performans göstermiştir. Ancak, son işlem fonksiyonlarını desteklememesi, bu donanımın diğer yöntemlerle kıyaslandığında daha sınırlı bir esneklik sunduğunu ortaya koymaktadır. Bununla birlikte modellerin NPU donanımına uygun hale getirilerek test edilmesine rağmen yüksek çözünürlüklü testlerde beklenen performans artışını sağlayamamıştır.

Genel olarak, Jetson Orin Nano üzerinde çalışan YOLOv8 modeli, gerek çözünürlük gerekse performans açısından en ideal çözüm olarak öne çıkmaktadır. Bu model, 512x512 piksel giriş çözünürlüğü ve PostDAS yöntemiyle üstün bir performans sunarak gerçek zamanlı analizler için en verimli kombinasyonu temsil etmektedir. Özellikle termal görüntüleme ve yoğun hesaplama gerektiren senaryolarda, Jetson Orin Nano ve YOLOv8 modeli birlikte ideal bir tercih olarak değerlendirilmektedir. Bu sonuçlar, donanım ve model optimizasyonunun doğru yapılandırıldığında uygulama verimliliğini nasıl artırabileceğini açıkça göstermektedir.

4.4. Uç Cihazlar Arası Haberleşme

Bu bölümde, birden fazla uç cihazın kullanıldığı uygulamalar için geliştirilen yöntemin ayrıntıları açıklanmaktadır. Uç cihazlar, gözlem yaptıkları doğrultuda hedef tespiti yaparak bireysel işlevlerini yerine getirirken, izledikleri bölgede aynı nesneyi tespit etmeleri ve bu durumu birbirleriyle iletişim kurarak kullanıcıya bildirmeleri, grup halinde kullanım etkinliğini artırmaktadır. Bu yaklaşım, uç cihazların hem bireysel hem de kolektif işlevselliğine katkı sağlamaktadır.

Şekil 4.14 uç cihazların tespit ettiği bir objenin diğer uç cihazlara iletilmesi ve bu cihazlarda eşleşen objenin işaretlenmesine yönelik gerçekleştirilen çalışmanın detayları sunulmuştur. Uç cihazlar arasında iletişim, UDP protokolü kullanılarak sağlanmıştır. Cihazlar, aynı ağa bağlı olmak koşulu ile UDP üzerinden, önceden belirlenmiş gönderici ve alıcı portu aracılığıyla ana bilgisayar ile veri iletişimi gerçekleştirmektedir. Ana bilgisayar tüm uç cihazlardan gelen bilgileri analiz ederek sistemin yönetilmesini sağlamaktadır. Her uç cihazın ana bilgisayar ile iletişimi iki adet gönderici ve bir adet alıcı olmak üzere üç farklı port ile sağlanmaktadır.




Şekil 4.14. Uç cihazların birbiri ile haberleşmesi

Ana bilgisayar ile sağlanan iletişim için kullanılan veri paketi, gönderilen ve alınan paket olmak üzere iki tür oluşmaktadır. Uç cihazlar tarafından ana bilgisayara gönderilen veri paketi aşağıdaki bileşenleri içermektedir:

- Objelerin Görüntüsü: Tespit edilen objelerin kırılarak yan yana eklenmiş hali.


- Objelerin Ebat Bilgileri: Her bir objenin piksel cinsinden ifade edilen boyut bilgisi.
- Kimlik Bilgileri: Her obje için atanmış benzersiz kimlik bilgileri.
- Seçilen Objeye Ait Kimlik: Eğer bir obje seçilmişse, bu objeye ait kimlik bilgisi.

Gönderici portlardan biri yalnızca görüntü verisini aktarırken, diğer port meta veri ve kimlik bilgilerinin iletimi için kullanılmaktadır (Şekil 4.15). Bu ayırım, veri akışının daha düzenli ve hızlı olmasını sağlamaktadır.



Şekil 4.15. Uç cihazların ana bilgisayara veri gönderme formatı


Uç cihazlar tarafından alınan veri paketi içeriğinde, diğer uç cihazlardan seçilen nesnenin kimlik bilgisinin alıcı tarafta bulunan uç cihazdaki karşılığı olan kimlik bilgisi bulunmaktadır (Şekil 4.16). Eşleştirme ve dağıtma işlemi ana bilgisayar üstlenmektedir.



Şekil 4.16. Uç cihazların ana bilgisayardan veri alma formatı

Ana bilgisayar, uç cihazlardan gelen görüntü ve meta verileri iki farklı port üzerinden alır ve sırası ile şu işlemleri gerçekleştirir:

- Görüntü Ayırıştırma ve Listeleme: Tespit edilen objelere ait görüntüler, ebat bilgileri kullanılarak ayrıştırılarak bir listeye eklenir. Bu liste, eşleştirme süreçleri için temel oluşturur.
- Kimlik Bilgisi Eşleştirme: Her obje için alınan kimlik bilgileri, ayrıştırılan görüntüler ile eşleştirilir ve listeye eklenir. Böylece uç cihaz üzerinde algılanan obje-kimlik bilgisi çifti ana bilgisayara aktarılmış olur. Her uç donanım aynı objeyi tespit etmesine karşın farklı kimliklendirme atayabileceği unutulmamalıdır.
- Benzerlik Analizi: Her uç cihazlardan gelen görüntüler için ayrı ayrı tutulan listeler, Yapısal Benzerlik İnteksi (YBİ, Eşitlik 4.6) yöntemi kullanılarak birbirleri ile karşılaştırılır. Bu süreçte, benzerlik oranları hesaplanarak obje kimlik bilgileri akümülatör matrisine kaydedilir.
- Akümülatör Matrisi: Her karşılaştırma sonucunda elde edilen veriler akümülatör matrisine eklenir. Eğer daha önce eşleşen objeler varsa önceki benzerlik oranı ile yeni oran toplanarak matrise kaydedilir. Bu matris, tüm objelerin benzerlik analizine dayalı olarak sıralandığı ve en yüksek eşleşmeye sahip objelerin belirlendiği bir yapı sunar (Şekil 4.17).




Şekil 4.17. Ana bilgisayar veri ayrıştırma ve benzerlik analizi

$$YBI(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad 4.6$$

Bu eşitlikte; μ_x, μ_y x ve y görüntülerinin ortalama parlaklığı, σ_x^2, σ_y^2 x ve y görüntülerinin varyansları, σ_{xy} x ve arasındaki kovaryans, C_1, C_2 sabit değerlerdir (Zhou Wang ve diğ., 2004).

Her obje diğer uç cihazlardan gelen görüntüler ile YBI karşılaştırılır ve sonuçları listede saklanır. Oluşan liste içerisinde karşılaştırılan objelerin kimlik bilgileri ve benzerlik oranları bulunmaktadır. Alınan her görüntüden sonra bu hesaplama yenilenir ve en yüksek benzerliğe sahip eşleşme önceki veriler ile toplanarak akümülatör matrisi içerisine yazılır. Akümülatör matrisi incelendiğinde karşılaştırılan görüntülerden en yüksek eşleşmeye sahip olanlarının listesinin yer aldığı görülecektir. Herhangi bir uç cihazdan gelen obje seçim bilgisi ve kimlik numarası bu akümülatör matrisi içerisinde taranır ve eşleşen kimlik bilgileri ilgili uç donanımlara iletilir. Uç cihazlar bu bilgiyi kullanarak yapılan seçimi kendi görüntüleri üzerinde işaretleyerek belirtir (Şekil 4.18). Bu yapı, uç cihazlar arasında veri bütünlüğünü ve eş zamanlılığı optimize edecek şekilde geliştirilmiştir.



Şekil 4.18. Ana bilgisayar veri ayrıştırma ve benzerlik analizi

Bu bölümde, birden fazla uç cihazın aynı bölgeye yönlendirildiği durumlarda, tespit edilen bir objenin diğer uç cihazlara iletilmesi ve bu cihazlarda eşleşen objenin işaretlenmesine yönelik gerçekleştirilen çalışmanın teknik detayları ele alınmaktadır. Söz konusu yapı, uç cihazlar arasında koordinasyonun sağlanmasını ve ana bilgisayar ile cihazlar arasında gerçek zamanlı veri akışını mümkün kılacak şekilde tasarlanmıştır. Sistem, iletişim protokolü olarak UDP kullanılarak geliştirilmiştir ve bu protokol üzerinden hızlı ve düşük gecikmeli veri transferi gerçekleştirilmiştir.

5. SONUÇLAR VE ÖNERİLER

Uç donanımlar, taşınabilir yapıları sayesinde birçok alanda kullanım imkânı sunmalarına rağmen, sınırlı işlem gücü, enerji tüketimi ve bellek kapasitesi gibi kısıtlamalarla karşı karşıya kalmaktadır. Bu tür kısıtlamalar, özellikle derin öğrenme ve görüntü işleme gibi yüksek hesaplama gücü gerektiren uygulamalarda belirgin hale gelmektedir. Uç cihazlar üzerinde termal görüntü işleme ve obje tespitine yönelik algoritmaların geliştirilmesi, bu cihazların sınırlamalarını göz önüne alarak özel optimizasyon gerektirmektedir. Tez kapsamında, uç donanımlarda optimize edilmiş termal görüntüleme tabanlı obje tespit modelleri geliştirilmiş ve bu modellerin verimliliği artırılmıştır. Ayrıca, uç cihazlar arasında bir iletişim ağı oluşturularak durumsal farkındalığın artırılması sağlanmıştır.

5.1 Sonuçlar

Obje tespit modellerinin son işlem algoritmalarının CPU üzerin çalıştırıldığı tespit edilmiş ve GPU biriminin daha etkili kullanılması için bu algoritmalar modelin içerisine eklenmiştir. Bu sayede son işlem fonksiyonları GPU üzerinde çözülürken CPU kaynak tüketimi hafifletilerek uç cihazın diğer işlemleri (çevresel sensör analizleri, robotik algoritmaların analizi vb.) için kullanılabilir hale getirilmiştir. Düşük güç tüketimine sahip Jetson Orin Nano, Jetson Orin NX, Jetson Nano, Jetson Xavier NX ve RK3588 gibi uç cihazlar üzerinde geliştirilen bu yapay zeka modelleri test edilmiştir.

Model ve donanımların performans ölçümü için birim güç başına üretilen değer metriği kullanılmaktadır ve tez kapsamında FPS/Watt kullanılmıştır (Huppler, 2013, Juárez ve diğ., 2016, Degnan ve diğ., 2016). Akenine-Möller ve Johnsson'ın (2012) araştırmalarında da güç başına performans metriklerinin, donanımların gerçek enerji verimliliğini her zaman doğru şekilde ifade etmediği tartışılırken bunun yerine işlem başına enerji veya iş birimi başına güç hesaplanması gerektiğini önerilmiştir. Önerilen bu yöntemlerde obje tespit modellerinin doğruluk performansının ölçüm metriklerine dahil edilememesi sonuçların yanlış değerlendirilmesine yol açmaktadır. Bu sebeple obje tespit modellerinin performans kriteri olan GOH değerinin hesaplamalara katıldığı ve verimlilik karşılaştırması için RSH ve RSHAY değerlendirme parametleri oluşturulmuştur. RSH parametresi ile uç donanımda çalışan obje tespit modellerinin aynı çözünürlük değerindeki verimliliği ölçülebilir hale gelmiştir. RSHAY parametresi ile uç donanım

sayısının birden fazla olduğu durumlarda uç donanımların, modellerin ve çözünürlüğe bağlı performanslarının kıyaslanması mümkün hale gelmiştir. Literatüre kazandırılan bu iki parametre sayesinde bataryalı sistemler için en verimli uç cihaz- obje tespit modeli çiftinin doğru bir şekilde belirlenmesi sağlanmıştır. Her bir donanım için en uygun modeller, RSH ve RSHAY performans puanlamaları dikkate alınarak belirlenmiştir.

Çalışmada, toplamda 14.400 termal görüntü içeren veri seti, FLIR veri seti temel alınarak oluşturulmuş ve bu veri seti, YOLOX, Gold-YOLO, YOLOv8, YOLOv9 ve YOLOv10 olmak üzere beş farklı tek aşamalı obje tespit modelinin eğitimi için kullanılmış, farklı uç cihazlardaki güç tüketim ve FPS değerleri kayıt altına alınmıştır. Elde edilen sonuçlara göre, termal görüntülerde küçük objelerin tespitinde en başarılı model, 224x224 piksel çözünürlükte %63,5 GOH ile YOLOv10 olmuştur. Jetson ailesine ait uç cihazlarda 224x224 piksel çözünürlükte en yüksek RSHAY puanını alan modelin yine YOLOv10 olduğu ve bu çözünürlükteki en verimli model olduğu tespit edilmiştir. 320x320, 512x512 ve 640x640 çözünürlüklerde ise YOLOv8 mimarisinin omurga, boyun ve kafa yapısının termal görüntüleme için en uygun obje tespit modeli olduğu görülmüştür. Aynı zamanda, bu çözünürlüklerde YOLOv8 modellerinin en yüksek RSHAY parametresine sahip olması, bu modelin donanımlar üzerinde de verimli çalıştığını göstermiştir. Gold-YOLO modeli, 5,6M parametre sayısına sahip olmasına rağmen hiçbir çözünürlükte en iyi sonucu verememiştir. Bu durum, modelin termal görüntülerden özellik çıkarma ve obje tespit etme mimarisinin yetersiz olduğunu ortaya koymaktadır. YOLOv9, düşük parametre sayısına rağmen YOLOv8 ile benzer doğruluk oranlarına ulaşmış, ancak hesaplama maliyetlerinin yüksek olması nedeniyle uç donanımlar için verimlilik açısından dezavantajlı hale gelmiştir. Düşük parametre sayısına rağmen düşük GOH değeri sunan YOLOX modeli ise yalnızca Jetson Xavier NX cihazında 512x512 piksel çözünürlük için en verimli sonuçları üretebilmiştir. Bununla birlikte donanım optimizasyonu ile RK3588 uç cihazında 224x224 piksel çözünürlükte verimli bir sonuç elde edebilmiştir. Bu değerlendirmeler sonucunda test edilen donanımların, obje tespit modellerin ve son işlem yöntemlerinin tamamı değerlendirildiğinde, Jetson Orin Nano üzerinde çalışan 512x512 piksel çözünürlükte YOLOv8 PostDas modelinin en verimli model olduğu sonucuna ulaşılmıştır. Bununla birlikte GOH puanının performans karşılaştırmasına dahil edilmesi, yapılan kıyaslamaların daha doğru şekilde yapılmasının önünü açarak geliştirilen RSH ve RSHAY parametrelerinin önemini göstermiştir.

Uç cihazlar arasında UDP protokolü kullanılarak 33 milisaniye gecikmeli veri iletimi sağlanarak düşük gecikmeli bir iletişim ağı kurulmuştur. Bu ağ, cihazlar arasında gerçek zamanlı veri paylaşımını mümkün kılmıştır. Termal görüntülerin işlenmesi sonucunda elde edilen obje tespit bilgileri, diğer cihazlarla paylaşılmıştır. Termal görüntülerde tespit edilen objelerin özellikleri, boyutları ve kimlik bilgileri merkezi bir ana bilgisayara iletilmiştir. Ana bilgisayar, uç cihazlardan gelen bu bilgileri analiz ederek obje eşleştirmelerini gerçekleştirmiş ve kimlik bilgilerini güncelleyerek cihazlara geri iletmıştır. Bu süreçte, görüntü benzerliği analizleri için YBİ kullanılmış ve elde edilen eşleşme puanları akümülatör matrisinde kaydedilmiştir. YBİ tabanlı analiz, yüksek doğrulukla eşleşme sağlarken, gerçek zamanlı işleme gereksinimlerini karşılamıştır.

5.2 Öneriler

Tez çalışması kapsamında edilen sonuçlar, uç cihazların derin öğrenme tabanlı obje tespit uygulamalarında verimli bir şekilde kullanılabilceğini göstermiştir. Uygulanan optimizasyon stratejileri, işlem gücü sınırlamalarına rağmen, cihazların performansını önemli ölçüde artırmıştır.

Bu çalışmada test edilen modellerin donanım optimizasyonu yapılmadan ONNX formatında olmasına rağmen, Jetson ürün ailesinde yüksek verimlilikle çalıştığı gözlemlenmiştir. Ancak, NVIDIA'nın GPU birimlerinin daha verimli kullanılabilmesi için geliştirdiği kuantizasyon yöntemlerinin kullanımının, performans üzerinde ek bir artış sağlayabileceği değerlendirilmektedir.

Bunun yanı sıra, Rockchip firmasının NPU biriminin YOLOv9 ve YOLOv10 modellerinde kullanılan fonksiyonları desteklemesi durumunda, modellerin performanslarının ölçülmesi ve kıyaslama parametrelerinin hesaplanarak karşılaştırmaya dahil edilmesi mümkün olacaktır. Bu durum, modellerin uç cihazlar üzerinde sağladığı performans farklarının daha detaylı bir şekilde analiz edilmesini sağlayacaktır. Ayrıca, son işlem yöntemlerinde kullanılan fonksiyonların da RK3588 işlemcisinin NPU birimi tarafından desteklenmesi durumunda, ölçüm parametreleri çeşitlendirilerek daha sağlıklı ve kapsamlı bir karşılaştırma yapılabilecektir.

Termal görüntüleme ile gerçekleştirilen bu çalışmanın, görünür ışık kameraları ile alınan görüntülere uygulanabilir bir yapıya dönüştürülmesi, kullanım alanını genişletecek önemli bir adım olarak değerlendirilmektedir. Görünür ışık ve termal görüntülerin birlikte kullanıldığı durumlarda, görüntü füzyonu teknikleri uygulanarak elde edilen bilgilerin

operatörün karar verme süreçlerini destekleyici etki sağlayacağı öngörülmektedir. Bu sayede, uç cihazlar arası bilgi paylaşımı ve entegrasyon ile karar destek sistemlerinin daha etkili hale getirilmesi mümkün olacaktır.

Tez çalışmasında elde edilen sonuçlar, uç cihazların daha karmaşık ve büyük ölçekli sistemlerde kullanım potansiyelini ortaya koymaktadır. İlerleyen araştırmalarda, daha hafif derin öğrenme modellerinin geliştirilmesi, enerji tüketiminin daha da azaltılması ve iletişim protokollerinin daha büyük ağlarda test edilmesi önerilmektedir. Ayrıca, alternatif eşleştirme metriklerinin ve makine öğrenimi tabanlı optimizasyon algoritmalarının sistem performansını artırmak için kullanılabileceği düşünülmektedir.

Sonuç olarak, tez çalışması, uç cihazların termal görüntülerle entegre çalışabilmesi ve veri paylaşımı yoluyla durumsal farkındalığın artırılması konusunda önemli bir katkı sunmaktadır. Geliştirilen sistem, dinamik uygulamalarda verimli, güvenilir ve gerçek zamanlı bir çözüm olarak değerlendirilebilir.

KAYNAKLAR

- Aksoy, T., 2022, Improvements on one-stage object detection by visual reasoning, Yüksek Lisans Tezi, *Middle East Technical University*.
- Akenine-Möller T. ve Johnsson B., 2012, Performance per What?, *Journal of Computer Graphics Techniques (JCGT)*, vol. 1, no. 1, 37-41, 2012.
- Akula, A., Ghosh, R., ve Sardana, H. K., 2011, Thermal Imaging And Its Application In Defence Systems, *AIP Conf Proc*, 1391.
- Arrue, B.C., Ollero, A. ve Matinez de Dios, J.R. 2000, An intelligent system for false alarm reduction in infrared forest-fire detection, *IEEE Intell. Syst. Appl.*, 15(3), 64–73.
- Baek, I., Chen, W., Venkat, A. C. ve Rajkumar, R. R., 2021, Practical Object Detection Using Thermal Infrared Image Sensors, *2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)*, 372-379.
- Batchuluun, G., Kang, J. K., Nguyen, D. T., Pham, T. D., Arsalan, M. ve Park, K. R., 2021, *Deep Learning-Based Thermal Image Reconstruction and Object Detection*, *IEEE Access*, 9, 5951-5971.
- Berg, A., 2016, Detection and Tracking in Thermal Infrared Imagery, *Linköping University Electronic Press*, 66.
- Bingöl H., 2012, Termal ve hiperspektral görüntülerde hareketli hedef tespiti ve izlenmesi, Yüksek Lisans Tezi, *Ulusal Tez Merkezi*, 315993.
- Bochkovskiy, A., Wang, C. Y., ve Liao, H. Y. M., 2020, YOLOv4: Optimal Speed and Accuracy of Object Detection, *arXiv*, preprint arXiv:2004.10934.
- Bodla, N., Singh, B., Chellappa, R., ve Davis, L. S., 2017, Soft-NMS—Improving Object Detection with One Line of Code, *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 5561–5569.
- Bustos, N., Mashhadi, M., Lai-Yuen, S.K., Sarkar, S. ve Das, T.K., 2023, A systematic literature review on object detection using near infrared and thermal images, *Neurocomputing*, 560, 126804.
- Cao, Y., Zhou, T., Zhu, X. ve Su, Y., 2019, Every Feature Counts: An Improved One-Stage Detector in Thermal Imagery. *2019 IEEE 5th International Conference on Computer and Communications (ICCC)*, 1965-1969.
- Chang, S. Y., Chiao, H. T., Yeh, X. Y., ve Tseng, M. C., 2013, UDP-based file delivery mechanism for video streaming to high-speed trains, *2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 3568-3572.

- Chen, Y., Chen, Q., Hu, Q. ve Cheng, J., 2022, DATE: Dual Assignment for End-to-End Fully Convolutional Object Detection, *ArXiv*, abs/2211.13859.
- Choi, Y., Kim, N., Hwang, S. ve Kweon, I. S., 2016, Thermal Image Enhancement using Convolutional Neural Network, *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Kuzey Korea, 223-230.
- Darío G. L., Rubén U. ve Daniel F. G., 2024, Quantitative comparison and performance evaluation of deep learning-based object detection models on edge computing devices, *Integration*, Volume 95, 102127, ISSN 0167-9260.
- Davies J., 2022, Teledyne FLIR Releases Free Starter Dataset [online], <https://robopromedia.automateproeurope.com/teledyne-flir-releases-free-starter-dataset/> [Ziyaret Tarihi: 05 Nisan 2023].
- Degnan, B. P., Marr, B. ve Hasler, J. O., 2016, Assessing Trends in Performance per Watt for Signal Processing Applications. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 24, 58-66.
- Dios, J.R. ve Ollero, A., 2006, Automatic Detection of Windows Thermal Heat Losses in Buildings Using UAV, *2006 World Automation Congress*, 1-6.
- DSIAC, 2010, ATR Algorithm Development Image Database, <https://dsiac.org/databases/atr-algorithm-development-image-database/> [Ziyaret Tarihi: 01.11.2022].
- Ervural, S. ve Ceylan, M., 2021, Kızılötesi Termal Görüntülemenin Yapay Zeka Tabanlı Biyomedikal Uygulamaları, *Sağlık Bilimlerinde Yapay Zeka Dergisi*, 1(1), 24-34.
- Farooq, M. A., Corcoran, P., Rotariu, C. ve Shariff, W., 2021, Object Detection in Thermal Spectrum for Advanced Driver-Assistance Systems (ADAS), *IEEE Access*, 9, 156465-156481.
- Farooq, M. A., Shariff, W., Khan, F. ve Corcoran, P., 2023, Development, optimization, and deployment of thermal forward vision systems for advance vehicular applications on edge devices, *International Conference on Machine Vision*, Vol. 12701, p. 1270102.
- Farooq, M.A., Shariff, W. ve Corcoran, P., 2022, Evaluation of Thermal Imaging on Embedded GPU Platforms for Application in Vehicular Assistance Systems, *IEEE Transactions on Intelligent Vehicles*, 8, 1130-1144.
- FLIR Systems, 2018, FLIR Thermal Dataset for Object Detection, <https://www.flir.com> [Ziyaret Tarihi: 08.11.2022].
- Gade, R. ve Moeslund, T.B., 2013, Thermal cameras and applications: a survey, *Machine Vision and Applications*, 25, 245- 262.
- Gallagher, J. ve Oughton, E., 2023, Assessing thermal imagery integration into object detection methods on air-based collection platforms, *Scientific Reports*, 13.

- Ge, Z., Liu, S., Wang, F., Li, Z. ve Sun, J., 2021, YOLOX: Exceeding YOLO series in 2021, *arXiv preprint arXiv:2107.08430*.
- Gowen, A. A., Tiwari, B. K., Cullen, P. J., McDonnell, K. ve O'Donnell, C.P., 2010, Applications of thermal imaging in food quality and safety assessment, *Trends Food Sci. Technol.* 21(4), 190–200.
- Hatipoğlu, R. S. ve Ceylan M., Termal görüntüler için Jetson NX tabanlı uç cihazda gerçek zamanlı obje tespit performansının incelenmesi, 25. *Otomatik Kontrol Ulusal Konferansı, TOK 2024*, Konya, 604-607.
- Hatipoğlu, R. S. ve Ceylan M., Investigation of real-time object detection performance for thermal images on RK3588 based edge device, *25th International Eurasian Conference on Science, Engineering and Technology, EurasianSciEnTech 2024*, Konya, 560-566.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2015, Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. ve Adam, H., 2017, MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint arXiv:1704.04861*.
- Huppler, K. R., 2013, Performance Per Watt - Benchmarking Ways to Get More for Less, In: Nambiar, R., Poess, M. (eds) *Selected Topics in Performance Evaluation and Benchmarking. TPCTC 2012, Lecture Notes in Computer Science*, 7755.
- Hussain, M., 2024, YOLOv5, YOLOv8 and YOLOv10: The Go-To Detectors for Real-time Vision, *ArXiv abs/2407.02988*.
- Ippalapally, R., Mudumba, S., Adkay, M. ve R., N.V., 2020, Object Detection Using Thermal Imaging, *2020 IEEE 17th India Council International Conference (INDICON)*, 1-6.
- Ivasic-Kos, M., Krišto, M. ve Pobar, M., 2019, Human Detection in Thermal Imaging Using YOLO, *Proceedings of the 2019 5th International Conference on Computer and Technology Applications*, 20-24.
- Jadin, M. S., Ghazali, K. H. ve Taib, S., 2013, Thermal condition monitoring of electrical installations based on infrared image analysis, *Saudi International Electronics, Communications and Photonics Conference*, 1-6.

- Jiang, C., Ren, H., Ye, X., Zhu, J., Zeng, H., Nan, Y., Sun, M., Ren, X. ve Huo, H., 2022), Object detection from UAV thermal infrared images and videos using YOLO models. *Int. J. Appl. Earth Obs. Geoinformation*, 112, 102912.
- Jin, T., Bercea, G. T., Le, T. D., Chen, T., Su, G., Imai, H., Negishi, Y., Leu, A., O'Brien, K. ve Kawachiya, K., 2020, Compiling onnx neural network models using MLIR, *arXiv preprint arXiv:2008.08272*.
- Jocher, G., 2023, YOLOv8: A state-of-the-art object detection and classification framework. *Ultralytics Documentation*.
- Jocher, G., 2021, Maximum and minimum image size [online], GitHub, <https://github.com/ultralytics/yolov5/issues/5987> [Ziyaret tarihi: 03.03.2023].
- Juang, J., Tu, G., Liao, Y., Huang, T. ve Chang, S., 2020, Drone patrol using thermal imaging for object detection, *Optical Engineering + Applications*, Sensors 21(16), 5330.
- Juárez, D. H., Espinosa, A., Moure, J. C., Vázquez, D. ve Peña, A. M., 2016, GPU-Accelerated Real-Time Stixel Computation. *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 1054-1062.
- Kamaleswari, P. ve Krishnaraj, N., 2023, An Assessment of Object Detection in Thermal (Infrared) Image Processing, *2023 Third International Conference on Artificial Intelligence and Smart Energy (ICAIS)*, 1498-1503.
- Kastek, M., Dulski, R., Trzaskawka, P., Sosnowski ve T., Madura, H., 2010, Concept of infrared sensor module for sniper detection system, *35th International Conference on Infrared Millimeter and Terahertz Waves*, 1-2.
- Kera, S.B., Tadepalli, A. ve Ranjani, J.J., 2022, A paced multi-stage block-wise approach for object detection in thermal images, *The Visual Computer*, 39, 2347- 2363.
- Kim, S., Shin, S. ve Moon, J., 2022, UDP-based Extremely Low Latency Streaming, *2022 IEEE 19th Annual Consumer Communications & Networking Conference (CCNC)*, 94-99.
- Krišto, M., Ivasic-Kos, M. ve Pobar, M., 2020, Thermal Object Detection in Difficult Weather Conditions Using YOLO, *IEEE Access*, 8, 125459-125476.
- Li, J. ve Ye, J., 2023, Edge-YOLO: Lightweight Infrared Object Detection Method Deployed on Edge Devices. *Applied Sciences*, 13(7), 4402.
- Lin, T. Y., Dollar, P., Girshick, R., He, K., Hariharan, B. ve Belongie, S., 2017, Feature Pyramid Networks for Object Detection, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2117-2125.
- Liu, S., Qi, L., Qin, H., Shi, J. ve Jia, J., 2018, Path Aggregation Network for Instance Segmentation, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 8759-8768.

- Maurer, T., Wilson, D.L. ve Driggers, R. G., 2013, Search and detection modeling of military imaging systems, *Optical Engineering*, 52.
- Mcewan, K., 2015, Military applications for high-performance thermal imaging, SPIE OPTO.
- Mohammed, H. L. ve Mahmood, A. F., 2023, A Survey of Streaming Protocols for Video Transmission, *NTU Journal of Engineering and Technology*, 2(1).
- Murthy, C. B., Hashmi, M. F., Bokde, N. D. ve Geem, Z.W., 2020, Investigations of Object Detection in Images/Videos Using Various Deep Learning Techniques and Embedded Platforms—A Comprehensive Review, *Applied Sciences*, 10(9), 3280.
- Narendran, M., Lakshmanan, M., Mohan, S., Sharma, L. ve Sharma, R. P., 2018, A Review on Object Detection in Thermal Imaging and Analysing Object and Target Parameters, *International Journal of Electrical, Electronics and Data Communication (IJEEDC)*, 69-72.
- Neubeck, A. ve Gool, L. V., 2006, Efficient Non-Maximum Suppression. *18th International Conference on Pattern Recognition (ICPR'06)*, 3, 850-855.
- Nguyen, D., Pham Dinh Quy ve Trinh Viet Ha., 2023, Recent advances in thermal imaging and its application in military, *Journal of Military Science and Technology*, 89(89), 173–176.
- Nguyen, T. X. B., Rosser, K. ve Chahl, J., 2021, A Review of Modern Thermal Imaging Sensor Technology and Applications for Autonomous Aerial Navigation, *Journal of Imaging*, 7(10), 217.
- Nimmi, S., Saranya, V. ve Gandhiraj, R., 2014, Real-time video streaming using GStreamer in GNU Radio platform, *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCCE)*, 1-6
- NVIDIA, 2019, NVIDIA Jetson Nano Developer Kit User Guide. NVIDIA Corporation.
- NVIDIA, 2020, Jetson Xavier NX Developer Kit User Guide. NVIDIA Corporation.
- NVIDIA, 2022, Jetson Orin Nano Developer Kit Datasheet. NVIDIA Corporation.
- NVIDIA, 2022, Jetson Orin NX Series Datasheet. NVIDIA Corporation.
- Pandurangan, K. ve Nagappan, K., 2024, A Deep Assessment of Thermal Image-Base Object Detection for a Wide Range of Applications, *2024 2nd International Conference on Artificial Intelligence and Machine Learning Applications Theme: Healthcare and Internet of Things (AIMLA)*, 1-7.
- Patel, H. ve Upla, K. P., 2020, Night Vision Surveillance: Object Detection using Thermal and Visible Images, *2020 International Conference for Emerging Technology (INCET)*, 1-6.

- Paugam, R., Wooster, M. ve Roberts, G., 2013, Use of handheld thermal imager data for airborne mapping of fire radiative power and energy and flame front rate of spread, *IEEE Trans. Geosci, Remote Sensing*, 51(6), 3385–3399.
- Peric, D. B., Livada, B., Perić, M. V. ve Vujic, S., 2019, Thermal Imager Range: Predictions, Expectations, and Reality. *Sensors*, 19.
- Rai, M. K., Maity, T. ve Yadav, R. K., 2017, Thermal imaging system and its real time applications: a survey, *Journal of Engineering Technology*, 62(2).
- Redmon, J. ve Farhadi, A., 2018, YOLOv3: An Incremental Improvement. *arXiv preprint arXiv:1804.02767*.
- Redmon, J., Divvala, S., Girshick, R., ve Farhadi, A., 2016, You Only Look Once: Unified, Real-Time Object Detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788.
- Rivadeneira, R. E., Suárez, P. L., Sappa, A. D. ve Vintimilla, B. X., 2019, Thermal image superresolution through deep convolutional neural network, *Image Analysis and Recognition: 16th International Conference, ICIAR 2019, Part II 16*, 417-426.
- Rogler, R. D., Lobl, H. ve Schmidt, J., 1996, A diagnostic system for live electrical joints in power transmission systems, *Forty-Second IEEE Holm Conference on Electrical Contacts. Joint with the 18th International Conference on Electrical Contacts*.
- Sachan, R., Kundra, S. ve Dubey, A. K., 2022, An Efficient Algorithm for Object Detection in Thermal Images using Convolutional Neural Networks and Thermal Signature of the Objects, *2022 4th International Conference on Energy, Power and Environment (ICEPE)*, 1-6.
- Scius-Bertrand, A., Jungo, M., Wolf, B., Fischer, A. ve Bui, M., 2021, Transcription Alignment of Historical Vietnamese Manuscripts without Human-Annotated Learning Samples, *Applied Sciences*, 11(11), 4894.
- Sharrab, Y. O., Al-shboul, S., Alsmirat, M. A., Khalifeh, A. F., Dwekat, Z., Alsmadi, I. ve Al-Khasawneh, A., 2021, Performance Comparison of Several Deep Learning-Based Object Detection Algorithms Utilizing Thermal Images, *2021 Second International Conference on Intelligent Data Science Technologies and Applications (IDSTA)*, 16-22.
- Shimoni, M., Haelterman, R. ve Perneel, C., 2019, Hypersectral Imaging for Military and Security Applications: Combining Myriad Processing and Sensing Techniques, *IEEE Geoscience and Remote Sensing Magazine*, 7, 101-117.
- Siegel, R., 2002, Land mine detection, *IEEE Instrum. Meas. Mag.*, 5(4), 22–28.
- Skladchykov, I., Momot, A., Galagan, R., Bohdan, H. ve Trotsiuk, K., 2022, Application of YOLOX deep learning model for automated object detection on thermograms. *Information extraction and processing*, 69-77.

- Soeleman, M. A., Supriyanto, C. ve Purwanto, 2023, Deep Learning Model for Unmanned Aerial Vehicle-based Object Detection on Thermal Images, *Revue d'Intelligence Artificielle*, 687-692.
- Song, G., Liu, Y., ve Wang, X., 2020, Revisiting the sibling head in object detector, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 11563–11572.
- Soomro, S. A., Mujtaba, M., Nasreen, N., Ehsan, A. ve Khalil, M., 2018, Heterogeneous Buffer Size Impact on UDP Performance for Real-Time Video Streaming Application, *International Journal of Advanced Computer Science and Applications*, 9.
- Tan, M. ve Le, Q., 2019, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, *Proceedings of the 36th International Conference on Machine Learning*, 6105–6114.
- Tirupathamma, M. ve Niranjan, V., 2020, Principles And Applications Of Infrared Thermal Imaging, *Telecommunications and Radio Engineering*, 79, 1177-1187.
- Vadivambal, R. ve Jayas, D., 2011, Applications of thermal imaging in agriculture and food industry a review, *Food Bioprocess Technol.*, 4, 186–199.
- Vollmer, M. ve Möllmann, K. P., 2010, Infrared Thermal Imaging: Fundamentals, *Research and Applications*.
- Zhou Wang, A. C. Bovik, H. R. Sheikh ve E. P. Simoncelli, 2004, Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, 13(4), 600-612.
- Wang, C. Y., Liao, H. Y. M., Wu, Y. H., Chen, P. Y., Hsieh, J. W. ve Yeh, I. H., 2020, CSPNet: A new backbone that can enhance learning capability of CNN. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, 390-391.
- Wang, C. Y., Bochkovskiy, A. ve Liao, H. Y. M., 2021, Scaled-YOLOv4: Scaling Cross Stage Partial Network, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 13029-13038.
- Wang, C. Y., Bochkovskiy, A. ve Liao, H. Y. M., 2023, YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 7464-7475.
- Wang, C., He, W., Nie, Y., Guo, J., Liu, C., Wang, Y. ve Han, K., 2024, Gold-YOLO: Efficient object detector via gather-and-distribute mechanism, *Advances in Neural Information Processing Systems*, 36.
- Wang, D., Chen, X., Yi, H. ve Zhao, F., 2019, Improvement of non-maximum suppression in RGB-D object detection, *IEEE Access*, 7, 144134-144143.

- Wang, L., Zhang, L. ve Ma, Y., 2017, Gstreamer accomplish video capture and coding with PyGI in Python language, *2017 First International Conference on Electronics Instrumentation & Information Systems (EIIS)*, 1-4.
- Wasaki, K., Shimoi, N., Takita, Y. ve Kawamoto, P.N., 2001, A smart sensing method for mine detection using time difference IR images, *International Conference on Multisensor Fusion and Integration for Intelligent Systems*, 133-139.
- Wu, Y., Chen, Y., Yuan, L., Liu, Z., Wang, L., Li, H., ve Fu, Y., 2020, Rethinking classification and localization for object detection, *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 10186–10195.
- Wong, W. K., Tan, P. N., Loo, C. K. ve Lim, W. S., 2009, An effective surveillance system using thermal camera, *International Conference on Signal Acquisition and Processing*, 13-17.
- Yanmaz, L. E., Okumus, Z. ve Dogan, E., 2007, Instrumentation of thermography and its applications in horses, *J. Anim. Vet. Adv.* 6(7), 858–862.
- You, S., Ji, Y., Liu, S., Mei, C., Yao, X. ve Feng, Y., 2022, A Thermal Infrared Pedestrian-Detection Method for Edge Computing Devices, *Sensors*, 22(17), 6710.
- Yuan, C. ve Agaian, S. S. (2022). BiThermalNet: a lightweight network with BNN RPN for thermal object detection. *Defense + Commercial Sensing*,
- Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R. ve Ren, D., 2020, Distance-IoU loss: Faster and better learning for bounding box regression, *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(7), 12993–13000.
- Zhou, K., Zhang, J., Liu, F. ve Wang, X., 2022, Gold-YOLO: Energy-Efficient Object Detection for Edge Devices, *Journal of Computer Vision and Applications*, 14(3), 210–224.