



MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI SİLAH TESPİT SİSTEMİ

*Kıyas KAYAALP¹, Tuba YILMAZ²

¹Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği, Isparta
²Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği
Anabilim Dalı, Isparta

(Geliş/Received: 04.02.2026, Kabul/Accepted: 10.04.2026, Yayınlanma/Published: 30.06.2026)

ÖZ

Ruhsatsız silahların yaygınlığı ve silahlı suçların artışı, kamu güvenliği açısından ciddi bir tehdit oluşturmaktadır. Bu çalışmada, güvenlik kamerası sistemlerinde gerçek zamanlı silah tespiti amacıyla YOLOv11, RT-DETR, SSD-Lite + MobileNetV3-Large ve FCOS modelleri karşılaştırmalı olarak değerlendirilmiştir. Üç farklı açık kaynak veri setinin birleştirilmesiyle oluşturulan 10.824 görüntülük veri seti kullanılmış, model performansları Precision, Recall, mAP@50 ve mAP@50:95 metrikleri üzerinden analiz edilmiştir. Deneysel sonuçlar, RT-DETR modelinin %99.7 Recall, %97.3 Precision ve yaklaşık %90 F1 skoru ile en yüksek performansı sergilediğini ortaya koymuştur. Web kamerası üzerinden gerçekleştirilen testlerde RT-DETR, değişken aydınlatma koşullarında tutarlı performans göstermiş ve silaha benzer nesnelere düşük yanlış pozitif oranı sağlamıştır. Elde edilen bulgular, RT-DETR modelinin güvenlik odaklı uygulamalar için umut vadeden bir yaklaşım sunduğunu göstermektedir.

Anahtar kelimeler: Silah tespiti, Derin öğrenme, RT-DETR, Gerçek zamanlı nesne tespiti, Güvenlik kamerası sistemleri

REAL-TIME WEAPON DETECTION SYSTEM USING MACHINE LEARNING

ABSTRACT

The prevalence of unlicensed firearms and the rise in gun-related crimes pose a serious threat to public safety. In this study, four deep learning models—YOLOv11, RT-DETR, SSD-Lite + MobileNetV3-Large, and FCOS—were comparatively evaluated for real-time weapon detection in surveillance systems. A dataset of 10,824 images, created by merging three open-source datasets, was used, and model performance was analyzed using Precision, Recall, mAP@50, and mAP@50:95 metrics. Experimental results demonstrated that RT-DETR achieved the highest performance with 99.7% Recall, 97.3% Precision, and approximately 90% F1 score. In real-time webcam tests, RT-DETR showed consistent detection under varying lighting conditions and maintained a low false positive rate for weapon-like objects. The findings suggest that RT-DETR offers a promising approach for security-oriented applications.

Keywords: Weapon detection, Deep learning, RT-DETR, Real-time object detection, Security camera systems

1. Giriş (Introduction)

Modern toplumların karşı karşıya kaldığı en kritik güvenlik sorunlarından biri, bireysel silahlanmanın kontrolsüz artışı ve buna bağlı olarak gelişen asayiş olaylarıdır [1]. Özellikle ruhsatsız silahların yaygınlığı, suçun önlenmesi ve kamu düzeninin korunması önündeki en büyük engellerden birini oluşturmaktadır [2]. İçişleri Bakanlığı tarafından paylaşılan veriler, bu tehdidin boyutlarını çarpıcı bir şekilde ortaya koymaktadır.

İçişleri Bakanlığı verileri ruhsatsız silahların toplumsal güvenlik açısından ciddi bir tehdit oluşturduğunu ortaya koymaktadır. İçişleri Bakanı Ali Yerlikaya'nın 15 Aralık 2024 tarihinde TBMM Genel Kurulu 2025 Bütçe Görüşmeleri'nde yaptığı açıklamaya göre, 2024 yılının 11 ayında düzenlenen MERCEK operasyonları kapsamında 99.277 adet ruhsatsız silah ele geçirilmiş ve 110.361 şahıs hakkında işlem yapılmıştır [3]. Bakan Yerlikaya, özellikle dikkat çekici bir istatistik paylaşmıştır: "Bu yılın 11 ayında, silahla işlenen kasten öldürme ve yaralama olaylarına ilişkin, her 10 suçun 8'i ruhsatsız silahla işlendi" [3].

Bu veri, silahla işlenen suçların %80'inin ruhsatsız silahlarla gerçekleştirildiğini göstermekte olup, güvenlik sistemlerinde otomatik silah tespit teknolojilerinin önemini açıkça ortaya koymaktadır. Ruhsatsız silahların yaygınlığı ve bunların suç işlemede kullanım oranının yüksekliği, güvenlik önlemlerinin geliştirilmesini zorunlu kılmaktadır [4].

Küresel ölçekte bakıldığında, ateşli silahların yol açtığı güvenlik ve halk sağlığı sorunlarının yalnızca ulusal sınırlarla sınırlı olmadığı açıkça görülmektedir. Özellikle Amerika Birleşik Devletleri örneği, silahlı şiddetin ulaştığı boyutları göstermesi açısından dikkat çekicidir. Centers for Disease Control and Prevention (CDC) verilerine göre, 2022 yılında ABD'de 48.000'den fazla silahla ilişkili ölüm kaydedilmiş ve bu durum günlük ortalama 132 can kaybına karşılık gelmiştir. Bu ölümlerin yarısından fazlası intihar, %40'tan fazlası ise ateşli silahlarla işlenen cinayetlerden kaynaklanmaktadır [5]. Ayrıca, kalabalık veya kapalı alanlarda birden fazla kişiyi hedef alan aktif silahlı saldırı olaylarında da artış rapor edilmiştir [6].

Bu küresel eğilimler, silahlı şiddetin yalnızca belirli ülkelere özgü bir sorun olmadığını, aksine farklı toplumsal ve coğrafi bağlamlarda benzer güvenlik açıkları yarattığını göstermektedir. Küresel ölçekte gözlemlenen bu riskler, ülkelerin kendi özgül güvenlik dinamiklerine uygun önleyici ve teknolojik müdahaleler geliştirmesini zorunlu kılmaktadır [7]. Bu bağlamda, ruhsatsız silahların yaygınlığı ve silahlı suçların niteliği dikkate alındığında, Türkiye'de kamu güvenliğinin sağlanmasına yönelik olarak geliştirilen video tabanlı gözetim ve erken uyarı sistemleri, küresel güvenlik sorunlarına verilen yerel ve uygulamaya dönük bir yanıt niteliği taşımaktadır [8].

Türkiye'de kamu güvenliğinin sağlanmasında video gözetim sistemleri kritik bir rol üstlenmektedir. MOBESE (MOBil Elektronik Sistem Entegrasyonu), 2001 yılından bu yana Türkiye'nin 81 ilinde faaliyet gösteren ve suç ile suçluyla mücadelede güvenlik kuvvetlerinin elini güçlendiren kameralı güvenlik sistemleridir. İçişleri Bakanlığı bütçesi ve il özel idareleri tarafından finanse edilen bu sistemler için önemli yatırımlar yapılmıştır. MOBESE Projesi, Polis İtranet İletişim Hattı (Pol-Net) üzerinden kapalı ve güvenli hatlarda çalışmaktadır [9].

Küresel ölçekte bakıldığında, güvenlik kamerası pazarı tarihsel bir ivmeyle hızla büyümektedir [10]. Bu büyümenin kökleri, 2000'li yılların başında gözetim teknolojilerinin "bilim kurgu objesi" olmaktan çıkıp gündelik hayatın bir parçası haline gelmesine dayanmaktadır. Nitekim 2006 yılında yayımlanan "A Report on the Surveillance Society" başlıklı kapsamlı çalışma, küresel gözetim endüstrisinin o dönemde dahi yıllık bazda diğer pek çok sektörden daha hızlı büyüdüğünü ve askeri teçhizatın sivil CCTV sistemlerine kadar geniş bir yelpazeyi kapsayan küresel pazar değerinin yaklaşık 1 trilyon ABD dolarına ulaştığını vurgulamaktadır [11]. Bu büyüme, yapay zeka destekli video analitik çözümlerine olan talebin artmasıyla doğrudan ilişkilidir. Özellikle derin öğrenme tabanlı nesne tespit sistemleri, güvenlik kameralarının etkinliğini önemli ölçüde artırmaktadır [12]. Bu küresel eğilimler doğrultusunda, güvenlik ve gözetim teknolojilerindeki dönüşümün ulusal politika ve stratejilere nasıl yansdığı, ülkelerin dijitalleşme ve yapay zekâ odaklı yaklaşımlarını incelemeyi gerekli kılmaktadır.

Türkiye, yapay zeka alanında stratejik adımlar atmaktadır. Cumhurbaşkanlığı Dijital Dönüşüm Ofisi Başkanlığı ile Sanayi ve Teknoloji Bakanlığı iş birliğinde hazırlanan "Ulusal Yapay Zeka Stratejisi 2021-2025", 20 Ağustos 2021 tarihli ve 31574 sayılı Resmî Gazete'de yayımlanarak yürürlüğe girmiştir. Bu strateji, Türkiye'nin yapay zeka alanındaki ilk ulusal strateji belgesi olma özelliğini taşımaktadır. Strateji, 6 stratejik öncelik, 24 amaç ve 119 tedbir içermektedir [13].

Ulusal Yapay Zeka Stratejisi'nin vizyonu, "müreffeh bir Türkiye için çevik ve sürdürülebilir yapay zeka ekosistemiyle küresel ölçekte değer üretmek" olarak belirlenmiştir [13]. 2025 hedefleri arasında yapay zeka alanının GSYİH'ya katkısının %5'e yükseltilmesi, istihdamın 50 bin kişiye çıkarılması ve uluslararası yapay zeka endekslerinde Türkiye'nin ilk 20 ülke arasında yer alması bulunmaktadır [14]. TÜBİTAK, 1711 sayılı Yapay Zeka Ekosistem Çağrısı kapsamında makine öğrenmesi, doğal dil işleme, bilgisayarlı görü ve derin öğrenme gibi teknolojilerin geliştirilmesini desteklemektedir [15].

Silah tespiti alanında derin öğrenme tekniklerinin kullanımı son yıllarda önemli bir araştırma alanı haline gelmiştir. Santos ve arkadaşları (2024) tarafından yapılan sistematik derleme çalışmasında, bu alanda en yaygın kullanılan modellerin Faster R-CNN ve YOLO mimarileri olduğu tespit edilmiştir. Araştırmacılar, mevcut yöntemlerin zorlu bağlamlarda sınırlı performans gösterdiğini ve otomatik silah tespiti alanında veri kümesi çeşitliliği, değerlendirme standartları ve gerçek dünya doğrulaması konularında önemli zorlukların bulunduğunu belirtmişlerdir [6].

Wang ve arkadaşları (2023), CCTV ortamlarında küçük nesne tespiti için optimize edilmiş bir YOLOv4 tabanlı silah tespit sistemi geliştirmişlerdir. Çalışmada, SCSP-ResNet yapısı ve alıcı alan geliştirme modülü önerilmiştir [16].

Yadav ve arkadaşları (2024) ise düşük ışık koşullarında silah tespiti için YOLOv7-DarkVision modelini geliştirmişlerdir. Model, %95,50 hassasiyet ve %93,41 F1-Skoru ile gece koşullarında başarılı sonuçlar elde etmiştir [17].

Berardini ve arkadaşları (2025), video gözetim sistemlerinde gerçek zamanlı silah tespitini iyileştirmek amacıyla uç yapay zekâ (edge AI) ve süper çözünürlük tabanlı bir yaklaşım önermiştir. Çalışmada geliştirilen YOLOS modelini, kenar cihazlarında çalışacak şekilde tasarlanmış ve YOLOv8 ile karşılaştırıldığında %10,2 oranında Ortalama Hassasiyet (AP) artışı sağlamıştır [18].

Lai ve Maples tarafından gerçekleştirilen çalışmada, gerçek zamanlı silah tespiti problemi erken dönem derin öğrenme tabanlı yaklaşımlar çerçevesinde ele alınmıştır. Çalışmada, TensorFlow tabanlı OverFeat evrişimli sinir ağı mimarisi kullanılarak gözetim görüntülerinde elde taşınan silahların tespiti ve sınıflandırılması hedeflenmiştir. Yaklaşık 3.000 görüntüden oluşan özel bir veri kümesi üzerinde yapılan deneylerde, ayarlanmış hiperparametreler ile %93 eğitim doğruluğu ve %89 test doğruluğu elde edilmiştir. Bununla birlikte, modelin çalışma süresinin gerçek zamanlı video uygulamaları için sınırlayıcı olduğu belirtilmiş ve doğruluk-hız dengesi açısından daha verimli mimarilere ihtiyaç duyulduğu vurgulanmıştır [19].

Mohamed ve arkadaşları (2020), CCTV görüntülerinde ateşli silahların tespiti amacıyla CNN tabanlı bir yöntem önermiş ve transfer öğrenme kullanarak performans artışı sağlamıştır. AlexNet ve GoogLeNet mimarileri üzerinde yapılan deneyler, yöntemin IMFDB veri kümesi üzerinde farklı silah türlerine uyarlanabilir olduğunu göstermiştir. Çalışma, insan operatörlere bağımlı geleneksel gözetim sistemlerinin sınırlılıklarını vurgulayarak, otomatik ve gerçek zamanlı silah tespit sistemlerine duyulan ihtiyacı açık biçimde ortaya koymaktadır [20].

Yukarıda özetlenen çalışmalar, video tabanlı silah tespiti alanında kullanılan yaklaşımların çeşitliliğini, farklı uygulama senaryolarını ve karşılaşılan temel zorlukları ortaya koymaktadır. Bununla birlikte, mevcut literatürde kullanılan mimariler, hedeflenen performans ölçütleri ve elde edilen sonuçlar arasında belirgin farklılıklar bulunmaktadır. Bu çalışmaları karşılaştırmalı ve bütüncül bir bakış açısıyla değerlendirebilmek amacıyla, literatürde öne çıkan bazı yaklaşımlar ve temel bulguları Tablo 1'de özetlenmiştir.

Tablo 1. Silah tespiti literatüründeki ilgili çalışmaların özeti (Summary of Related Works in the Weapon Detection Literature)

Çalışma	Yıl	Kullanılan Yöntem / Model	Temel Bulgular
Santos ve ark. [6]	2024	Faster R-CNN, YOLO (derleme)	YOLO ve Faster R-CNN en yaygın mimariler; veri çeşitliliği ve gerçek dünya doğrulaması önemli zorluklar
Wang ve ark. [16]	2023	YOLOv4 (SCSP-ResNet)	Küçük nesne tespiti için optimize edilmiş yapı; alıcı alan geliştirme ile performans artışı
Yadav ve ark. [17]	2024	YOLOv7-DarkVision	%95,50 hassasiyet ve %93,41 F1-skoru ile düşük ışıkta yüksek başarı
Berardini ve ark. [18]	2025	YOLOSR (Edge AI + Süper Çözünürlük)	YOLOv8'e kıyasla %10,2 AP artışı; kenar cihazlar için uygunluk
Lai & Maples [19]	2017	OverFeat tabanlı CNN (TensorBox, sliding-window)	%93 eğitim ve %89 test doğruluğu; gerçek zamanlılıkta hız sınırlamaları
Mohamed ve ark. [20]	2020	AlexNet, GoogLeNet (Transfer Öğrenme)	Transfer öğrenme ile performans artışı; insan operatör bağımlılığının azaltılması

Mevcut literatür, silah tespitine yönelik derin öğrenme tabanlı yaklaşımların doğruluk açısından önemli ilerlemeler sağladığını ortaya koymakla birlikte, gerçek zamanlı çalışma gereksinimleri, hesaplama maliyetleri ve farklı görüntü kaynaklarına uyarlanabilirlik gibi konularda çeşitli zorlukların devam ettiğini göstermektedir. Özellikle düşük çözünürlük ve değişken aydınlatma koşulları gibi faktörlerin, farklı video kaynaklarından elde edilen görüntülerde tespit performansını etkileyebileceği rapor edilmektedir. Bu çerçevede, literatürde sıklıkla tartışılan doğruluk-hız dengesi, video tabanlı silah tespit sistemlerinde gerçek zamanlı çalışabilen modellerin geliştirilmesinin neden kritik bir gereklilik olduğunu ortaya koymakta ve bu tür yaklaşımların değerlendirilmesini ön plana çıkarmaktadır.

Bu çalışmada, video tabanlı silah tespiti amacıyla derin öğrenme tabanlı bir sistem geliştirilmiş ve farklı kullanım senaryoları bağlamında değerlendirilmiştir. Çalışma kapsamında birden fazla derin öğrenme mimarisi denenmiş; sistemin gerçek zamanlı işleme kapasitesi, tespit doğruluğu ve uygulama esnekliği analiz edilmiştir. Geliştirilen sistemin genel iş akışı ve deneysel kurgu yapısı Şekil 1'de gösterilmiştir. Sistem, hedef uygulama alanı olarak güvenlik kamerası altyapıları göz önünde bulundurularak tasarlanmıştır; bununla birlikte, sistemin gerçek zamanlı çalışabilirliği web kamera üzerinden gerçekleştirilen canlı video testleri ile prototip düzeyinde doğrulanmıştır. Bu yaklaşım, önerilen sistemin yalnızca belirli bir kamera türüne değil, farklı video akışlarına uyarlanabilir olduğunu göstermektedir.

Derin Öğrenme Tabanlı Silah Tespit Sistemi



Şekil 1. Genel mimari ve deneysel şema (Overall Architecture and Experimental Scheme)

Türkiye’de silahla işlenen kasten öldürme ve yaralama suçlarının önemli bir bölümünün ruhsatsız silahlarla gerçekleştirildiği ve bu durumun kamu güvenliği açısından ciddi bir risk oluşturduğu dikkate alındığında [3], geliştirilen sistemin mevcut güvenlik altyapılarını destekleyici bir teknolojik çözüm olarak değerlendirilmesi mümkündür. Bu yönüyle çalışma, Ulusal Yapay Zekâ Stratejisi 2021–2025 kapsamında belirlenen hedeflerle uyumlu biçimde, yerli ve uygulanabilir akıllı güvenlik uygulamalarının geliştirilmesine katkı sağlamayı amaçlamaktadır [13].

2. Materyal ve Metot (Material and Method)

2.1. Deneysel ortam (Experimental setup)

Bu çalışmada gerçekleştirilen tüm model eğitimi ve test işlemleri, 13. nesil Intel® Core™ i7-13700H işlemci, 16 GB RAM ve 6 GB VRAM kapasitesine sahip NVIDIA GeForce RTX 3050 grafik birimi içeren bir sistem üzerinde yürütülmüştür. Deneylerde işletim sistemi olarak Windows 11 kullanılmıştır.

2.2. Veri setinin düzenlenmesi (Dataset preparation)

Bu çalışmada, güvenlik sistemlerinde kullanılmak üzere silah tespitine odaklanan bir nesne tespit problemi ele alınmıştır. İnsan (person) sınıfı, silahların genellikle insanlarla birlikte bulunduğu gerçek dünya senaryolarını daha iyi temsil edebilmek amacıyla bağlamsal bir sınıf olarak modele dahil edilmiştir. Çalışmada kullanılan veri seti, üç farklı açık kaynak veri setinin birleştirilmesiyle oluşturulmuştur. Bu veri setleri; Roboflow platformundan elde edilen Person-Weapon Datasets (10.257 görüntü) [21], Gun Surveillance (200 görüntü) [22] ve Weapon veri seti (367 görüntü) [23] şeklindedir. Birleştirme işlemi sonucunda toplamda 10.824 görüntüden oluşan kapsamlı bir veri seti elde edilmiştir. Şekil 2’de sunulan örnek görüntüler, veri setinin çeşitliliğini ortaya koymaktadır. Veri seti; farklı aydınlatma koşulları (gündüz, gece, yapay aydınlatma), çeşitli kamera açıları (yakın çekim, uzak plan, yan açı), değişken arka planlar (ofis, ev, dış mekan) ve farklı silah tutma pozisyonları içermektedir. Bu çeşitlilik, modelin gerçek dünya senaryolarına genelleme yapabilmesi açısından kritik öneme sahiptir. Ayrıca, güvenlik kamerası görüntülerini simüle eden gri tonlamalı ve düşük çözünürlüklü örnekler de veri setine dahil edilmiştir.



Şekil 2. Birleştirilmiş veri setinden örnek görüntüler (Sample Images from the Combined Dataset)

Veri seti, yaygın nesne tespit modelleriyle uyumlu olacak şekilde, her görüntü için sınıf etiketi ve normalize edilmiş bounding box koordinatlarını içeren standart bir etiketleme formatında hazırlanmıştır. Veri seti, modellerin performansını objektif bir şekilde değerlendirebilmek amacıyla eğitim (%80) ve doğrulama (%20) alt kümelerine ayrılmıştır.

Modelin genelleme kabiliyetini artırmak amacıyla eğitim sürecinde çevrimiçi veri artırma (data augmentation) teknikleri uygulanmıştır. Bu kapsamda; sınırlı açısal döndürme, ölçekleme ve öteleme işlemleri ile yatay çevirme gibi geometrik dönüşümler gerçekleştirilmiştir. Ayrıca HSV renk uzayında doygunluk ve parlaklık varyasyonları kullanılarak aydınlatma koşullarındaki değişimlere karşı dayanıklılık artırılmıştır. Erken epoch'larda mozaik artırma tekniğinden faydalanılmış, ancak hassas konum tahmini gerektiren nesnelere üzerindeki olası olumsuz etkileri azaltmak amacıyla eğitim sürecinin son aşamalarında mozaik artırma devre dışı bırakılmıştır.

Güvenlik odaklı uygulama senaryoları göz önünde bulundurularak, MixUp, Copy-Paste ve etiket yumuşatma (label smoothing) gibi sınıf belirsizliği oluşturabilecek yöntemler bilinçli olarak kullanılmamıştır. Bu yaklaşım, modelin tahmin güvenilirliğini ve sınıf ayırma netliğini korumayı amaçlamaktadır.

2.3. Değerlendirme ölçütleri (Evaluation metrics)

Nesne tespit modellerinin performansını karşılaştırmalı olarak değerlendirmek amacıyla dört temel metrik kullanılmıştır: Kesinlik (Precision), Duyarlılık (Recall), mAP@50 ve mAP@50:95. Bu metrikler, modellerin yanlış alarm üretme eğilimi, pozitif örnekleri yakalama başarısı ve farklı örtüşme seviyelerindeki konumlandırma doğruluğunu ölçerek kapsamlı bir karşılaştırma sağlamaktadır.

Karşılaştırma sonucunda en iyi performansı gösteren model belirlendikten sonra, bu modelin karar verme davranışını daha ayrıntılı incelemek amacıyla F1 skoru kullanılmıştır. F1 skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalaması olup, özellikle dengesiz veri setlerinde model performansını tek bir değer üzerinden değerlendirmeye olanak tanımaktadır. Ayrıca, F1 skorunun farklı güven eşiği değerlerine bağlı değişimi analiz edilerek, model için optimum güven eşiği belirlenmiştir.

Kesinlik (Precision): Modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Bu metrik, yanlış pozitif tahminleri azaltma gücünü ölçmektedir.

$$\text{Kesinlik} = DP / (DP + YP) \quad (1)$$

Burada DP (Doğru Pozitif), modelin doğru şekilde pozitif olarak tahmin ettiği örnek sayısını; YP (Yanlış Pozitif) ise modelin hatalı şekilde pozitif olarak tahmin ettiği örnek sayısını ifade etmektedir.

Duyarlılık (Recall): Gerçek pozitif örneklerin ne kadarının doğru şekilde tahmin edildiğini ifade eder. Kaçırılan pozitif vakaları azaltma gücünü göstermektedir.

$$\text{Duyarlılık} = DP / (DP + YN) \quad (2)$$

Burada YN (Yanlış Negatif), modelin hatalı şekilde negatif olarak tahmin ettiği gerçek pozitif örnek sayısını ifade etmektedir.

mAP@50 (Mean Average Precision at IoU=0.50): IoU (Intersection over Union) eşik değeri 0.50 olarak alındığında, tüm sınıflar için hesaplanan ortalama hassasiyet değeridir. Bu metrik, tahmin edilen bounding box ile gerçek bounding box arasındaki örtüşme oranının en az %50 olması durumunda tahmini doğru kabul etmektedir.

$$mAP@50 = (1/N) \times \sum AP_i \quad (3)$$

Burada N, toplam sınıf sayısını; AP_i ise i. sınıf için hesaplanan Average Precision değerini ifade etmektedir.

mAP@50:95 (Mean Average Precision at IoU=0.50:0.95): IoU eşik değerinin 0.50'den 0.95'e kadar 0.05 artışlarla değiştirilmesiyle hesaplanan ortalama mAP değeridir. Bu metrik, modelin farklı örtüşme seviyelerindeki performansını değerlendirerek daha kapsamlı bir analiz sağlamaktadır.

$$mAP@50:95 = (1/10) \times \sum mAP@IoU \quad (4)$$

Bu formülde, IoU değerleri 0.50, 0.55, 0.60, ..., 0.95 olmak üzere 10 farklı eşik değerinde hesaplanan mAP değerlerinin ortalaması alınmaktadır.

F1 Skoru: Kesinlik ve Duyarlılık metriklerinin harmonik ortalamasıdır. Bu metrik, her iki ölçütü de dengeli bir şekilde değerlendirerek modelin genel performansını tek bir değerle ifade etmektedir.

$$F1 = 2 \times (Kesinlik \times Duyarlılık) / (Kesinlik + Duyarlılık) \quad (5)$$

F1 skoru, 0 ile 1 arasında değer almakta olup, 1 değeri mükemmel performansı temsil etmektedir. Bu metrik, özellikle dengesiz veri setlerinde modelin performansını değerlendirmek için tercih edilmektedir.

2.4. Algoritma seçimi (Algorithm selection)

Bu çalışmada, nesne tespit alanında güncel ve başarılı performans sergileyen dört farklı derin öğrenme modeli değerlendirilmiştir. Seçilen modeller, farklı mimari yaklaşımları temsil etmekte olup gerçek zamanlı güvenlik uygulamaları için uygunlukları karşılaştırmalı olarak analiz edilmiştir.

YOLOv11, Ultralytics tarafından Eylül 2024'te resmi olarak yayınlanan YOLO sürümüdür [24]. Bu model, tek aşamalı (single-stage) nesne tespit yaklaşımını benimsemekte olup, önceki YOLO versiyonlarına kıyasla geliştirilmiş özellik çıkarma mekanizmaları ve optimize edilmiş anchor-free tahmin başlıkları içermektedir. Gerçek zamanlı performansı ve yüksek doğruluk oranı ile güvenlik uygulamaları için ideal bir aday olarak değerlendirilmektedir [25].

RT-DETR (Real-Time Detection Transformer), 2023 yılında Baidu Research tarafından geliştirilen ve transformer tabanlı ilk gerçek zamanlı nesne tespit modelidir. DETR mimarisinin güçlü global bağlam modelleme yeteneklerini, gerçek zamanlı çıkarım hızıyla birleştirmektedir. Hibrit encoder yapısı sayesinde, hem CNN tabanlı lokal özellik çıkarımı hem de transformer tabanlı global ilişki modelleme kapasitesine sahiptir [26].

SSD-Lite + MobileNetV3-Large kombinasyonu, 2019 yılında tanımlanan hafif ve verimli bir nesne tespit mimarisidir. MobileNetV3 omurga ağı, düşük hesaplama maliyetiyle yüksek özellik çıkarma kapasitesi sunarken, SSD-Lite başlık yapısı çoklu ölçekte nesne tespiti gerçekleştirmektedir. Bu kombinasyon, özellikle kaynak kısıtlı ortamlar ve mobil uygulamalar için optimize edilmiştir [27].

FCOS (Fully Convolutional One-Stage Object Detection), 2019 yılında duyurulan anchor-free tek aşamalı bir nesne tespit mimarisidir. Geleneksel anchor tabanlı yöntemlerden farklı olarak, her piksel için doğrudan bounding box regresyonu gerçekleştirmektedir. Center-ness dalı sayesinde düşük kaliteli tahminleri filtreleyerek yüksek doğruluk oranları elde etmektedir [28].

Çalışmada kullanılan model varyantları şu şekildedir: YOLOv11 ailesinin beş farklı boyut seçeneği (nano, small, medium, large, xlarge) arasından YOLOv11-m (Medium) varyantı, doğruluk ve çıkarım hızı arasındaki denge gözetilerek tercih edilmiştir. RT-DETR ailesinin iki varyantı (Large ve Extra Large) arasından RT-DETR-l (Large) varyantı seçilmiştir; Large varyant yaklaşık 32 milyon parametre içermekte olup Extra Large varyanta (65 milyon parametre) kıyasla daha yüksek çıkarım hızı sunmaktadır. SSD-Lite için Torchvision kütüphanesinde tek varyant olarak sunulan ssdlite320_mobilenet_v3_large modeli, FCOS için ise omurga ağı olarak ResNet50 kullanılmıştır.

Tüm modellerde transfer öğrenme yaklaşımı uygulanmıştır: YOLOv11, COCO veri seti üzerinde ön eğitilmiş yolo11m.pt ağırlıkları ile başlatılmıştır. RT-DETR, COCO üzerinde ön eğitilmiş rtdetr-l.pt ağırlıkları ile başlatılmıştır. SSD-Lite modelinde Torchvision'ın SSdLite320_MobileNet_V3_Large_Weights.DEFAULT ağırlıkları kullanılmış olup omurga ağı (MobileNetV3-Large) ImageNet, tespit başlığı ise COCO veri seti üzerinde ön eğitilmiştir. FCOS modelinin omurga ağı olan ResNet50, ImageNet üzerinde ön eğitilmiş ağırlıklarla (ResNet50_Weights.IMAGENET1K_V2) başlatılmış; FPN ve FCOS Head katmanları sıfırdan eğitilmiştir. Transfer öğrenme kullanımı, 10.824 görüntüden oluşan veri seti boyutunda daha hızlı

yakınsama sağlamayı ve genel özellik temsillerinden faydalanarak genelleme performansını artırmayı amaçlamaktadır.

2.5. Eğitim konfigürasyonu (Training configuration)

Tüm modeller aynı veri seti üzerinde 50 epoch boyunca eğitilmiştir. Giriş görüntü boyutu YOLOv11, RT-DETR ve FCOS modelleri için 640×640 piksel, SSD-Lite modeli için ise 320×320 piksel olarak belirlenmiştir. Batch boyutu, modellerin bellek gereksinimleri göz önünde bulundurularak YOLOv11 ve SSD-Lite için 16, RT-DETR ve FCOS için 8 olarak ayarlanmıştır. Optimizasyon algoritması olarak YOLOv11, RT-DETR ve FCOS modellerinde AdamW, SSD-Lite modelinde ise SGD tercih edilmiştir.

AdamW optimizör tercihinin gerekçesi, bu algoritmanın adaptif öğrenme oranı ve düzgünleştirilmiş ağırlık azalması mekanizması sayesinde özellikle transformer mimarileri ve modern CNN yapılarında etkili sonuçlar üretmesidir. RT-DETR için $weight_decay=0.0001$, YOLOv11 için $weight_decay=0.0005$ olarak ayarlanmıştır; bu fark, transformer mimarisinin daha düşük düzenleme gerektirmesinden kaynaklanmaktadır. SSD-Lite modelinde SGD (momentum=0.9, $weight_decay=0.0005$) tercih edilmiş olup bu seçim Torchvision kütüphanesinin önerdiği standart eğitim konfigürasyonu ile uyumludur. Ayrıca SSD-Lite’da öğrenme oranı zamanlaması olarak StepLR scheduler kullanılmış ve her 10 epoch’ta öğrenme oranı 0.1 katına düşürülmüştür; bu yaklaşım diğer modellerde uygulanan cosine annealing stratejisinden farklıdır.

Öğrenme oranı, model mimarilerine göre farklılaştırılmıştır. YOLOv11 ve FCOS modelleri için 0.001, RT-DETR modeli için transformer mimarisinin hassasiyeti nedeniyle daha düşük bir değer olan 0.0001, SSD-Lite modeli için ise 0.01 başlangıç öğrenme oranı kullanılmıştır. YOLOv11 ve RT-DETR modellerinde 3 epoch warmup süresi uygulanmış, öğrenme oranı cosine annealing scheduler ile kademeli olarak azaltılmıştır. Aşırı öğrenmeyi önlemek amacıyla YOLOv11 modelinde 15 epoch, RT-DETR modelinde 20 epoch patience değeri ile early stopping mekanizması aktif edilmiştir.


SSD-Lite modelinde 320×320 giriş boyutu kullanılmasının nedeni, modelin mimari tasarımından kaynaklanmaktadır. Bu model, Torchvision kütüphanesinde `ssdlite320_mobilenet_v3_large` adıyla sunulmakta olup anchor boyutları, özellik piramidi katmanları ve algılama başlıkları 320×320 çözünürlüğe göre tasarlanmıştır. SSD-Lite, özellikle mobil ve kaynak kısıtlı cihazlar için geliştirilmiş hafif bir model olduğundan, düşük çözünürlük bu modelin tasarım felsefesinin bir parçasıdır. Bununla birlikte, bu boyut farklılığının küçük nesne tespitinde dezavantaj oluşturduğu ve SSD-Lite’in daha düşük Recall (%92.5) değerinin kısmen bu çözünürlük farkından kaynaklandığı değerlendirilmektedir.

Veri artırma stratejisi olarak geometrik ve renk tabanlı dönüşümler uygulanmıştır. YOLOv11 modelinde $\pm 15^\circ$, RT-DETR modelinde $\pm 10^\circ$ döndürme açısı kullanılmıştır. Her iki modelde de 0.5 olasılıkla yatay çevirme, mozaik augmentation ve HSV renk uzayında doygunluk ile parlaklık varyasyonları uygulanmıştır. RT-DETR modelinde, transformer mimarisinin hassas konum tahmini gerektirmesi nedeniyle son 10 epoch’ta mozaik augmentation devre dışı bırakılmıştır. Güvenlik uygulamalarında sınıf belirsizliğini önlemek amacıyla RT-DETR modelinde MixUp ve Copy-Paste teknikleri kullanılmamıştır.

3. Araştırma Bulguları (Research Findings)

Bu çalışmada, dört farklı nesne tespit modelinin performansına ilişkin karşılaştırmalı araştırma bulguları sunulmaktadır. YOLOv11, RT-DETR, SSD-Lite + MobileNetV3-Large ve FCOS modelleri, adil bir değerlendirme sağlamak amacıyla aynı veri seti ile eğitilmiş ve test edilmiştir.

Şekil 3’te görselleştirilen karşılaştırma grafiği, dört modelin dört farklı metrik üzerindeki performansını açıkça ortaya koymaktadır. Grafik incelendiğinde, YOLOv11 modelinin en yüksek Precision (0.992) ve mAP@50:95 (0.819) değerlerine ulaştığı görülmektedir. RT-DETR modeli ise en yüksek Recall değerine (0.997) sahip olup, neredeyse tüm pozitif örnekleri başarıyla tespit etmektedir. YOLOv11 ve RT-DETR modellerinin genel olarak diğer modellere kıyasla daha dengeli ve yüksek performans sergilediği görülmektedir.




Şekil 3. Modellerin performans karşılaştırması (Performance Comparison of Models)

3.1. RT-DETR model performans analizi (RT-DETR model performance analysis)

Gerçek zamanlı testlerde en iyi performansı sergileyen RT-DETR modeli, detaylı analiz için seçilmiştir. Modelin sınıflandırma performansı, karmaşıklık matrisi (confusion matrix) aracılığıyla Şekil 4'te sunulmaktadır.

Karmaşıklık matrisi analizi, RT-DETR modelinin her iki sınıf için de yüksek sınıflandırma performansı sergilediğini ortaya koymaktadır. Elde edilen sonuçlara göre, person sınıfına ait 801 gerçek örneğin 748'i doğru şekilde person olarak sınıflandırılırken, 53 örnek hatalı biçimde weapon olarak tahmin edilmiştir; bu durum person sınıfı için %93.4 doğruluk oranına karşılık gelmektedir. Benzer şekilde, weapon sınıfına ait 943 gerçek örneğin 872'si doğru şekilde weapon olarak tespit edilmiş, 71 örnek ise person olarak yanlış sınıflandırılmıştır ve bu sınıf için doğruluk oranı %92.5 olarak hesaplanmıştır. Özellikle güvenlik uygulamaları açısından kritik öneme sahip olan weapon tespitinde elde edilen yüksek başarı oranı, RT-DETR modelinin pratik kullanım potansiyelini desteklemektedir.



Şekil 4. RT-DETR modeli karmaşıklık matrisi (RT-DETR Confusion Matrix)

RT-DETR modelinin güven eşiği (confidence threshold) ile F1 skoru arasındaki ilişki Şekil 5'te analiz edilmektedir. Bu grafik, modelin optimal çalışma noktasının belirlenmesi açısından kritik öneme sahiptir.

Şekil 5'te görüldüğü üzere, weapon sınıfı için F1 skoru güven eşiğine bağlı olarak çan eğrisi şeklinde bir dağılım sergilemektedir. Optimal güven eşiği değeri yaklaşık 0.50 civarında konumlanmakta olup, bu noktada F1 skoru maksimum değerine (~0.90) ulaşmaktadır. Bu bulgu, modelin pratik uygulamalarda 0.50 güven eşiği ile kullanılmasının en dengeli Precision-Recall performansını sağlayacağını göstermektedir.

Grafik analiz edildiğinde, düşük güven eşiklerinde (0.0-0.2 arası) F1 skorunun düşük olduğu gözlemlenmektedir. Bu durum, düşük eşik değerlerinde modelin çok sayıda yanlış pozitif üretmesinden kaynaklanmaktadır. Öte yandan, yüksek güven eşiklerinde (0.8-1.0 arası) F1 skorunun tekrar düşmesi, modelin yüksek güvenle tahmin yapamadığı gerçek pozitif örnekleri kaçırmışından (yanlış negatif artışı) ileri gelmektedir.



Şekil 5. RT-DETR F1 skoru-güven eşiği (F1 Score vs. Confidence Threshold)

3.2. Gerçek zamanlı performans değerlendirmesi (Real-time performance evaluation)

Modellerin gerçek zamanlı performansı, web kamerası üzerinden canlı video akışı kullanılarak test edilmiştir. Gerçek zamanlı testlerde elde edilen sonuçlara göre modellerin performans sıralaması şu şekilde olmuştur:

1. **RT-DETR** – En yüksek gerçek zamanlı performans
2. **YOLOv11** – Yüksek doğruluk ile dengeli hız
3. **SSD-Lite + MobileNetV3-Large** – Orta düzey performans
4. **FCOS** – En düşük gerçek zamanlı performans

RT-DETR modelinin gerçek zamanlı testlerde en iyi sonucu vermesi, transformer tabanlı mimarisinin etkin global bağlam modelleme yeteneği ve optimize edilmiş çıkarım pipeline'ı ile açıklanabilir [6]. Model, özellikle karmaşık sahnelerde ve değişken aydınlatma koşullarında tutarlı tespit performansı sergilemiştir.

Şekil 6'da, farklı modellerin web kamerası üzerinden gerçek zamanlı silah tespiti gerçekleştirdiği anlık görüntüler sunulmaktadır. Bu görüntüler, modellerin pratik kullanım senaryolarındaki performansını somut olarak ortaya koymaktadır.

Şekil 6 incelendiğinde, sol taraftaki görüntüde SSD-Lite + MobileNetV3 ve YOLOv11 modellerinin silah tespiti gerçekleştirdiği görülmektedir. Sağ taraftaki görüntülerde ise RT-DETR modelinin performansı sergilenmektedir. RT-DETR, silah nesnelere %86 ve %74 güven değerleriyle tespit

ederken, özellikle dikkat çekici olan nokta, modelin el işareti yapan kişiyi ve elinde kalem tutan kişiyi yanlış pozitif olarak silah şeklinde sınıflandırmamış olmasıdır. Bu durum, RT-DETR modelinin yanlış pozitif oranını minimize etme konusundaki başarısını kanıtlamaktadır. RT-DETR modelinin daha düşük yanlış pozitif oranı ve daha akıcı çıkarım hızı, güvenlik uygulamaları için tercih edilmesinin temel gerekçelerini oluşturmaktadır.



Şekil 6. Gerçek Zamanlı Web Kamera Test Sonuçları (Real-Time Webcam Test Results)

4. Tartışma ve Sonuç (Results and Discussion)

Bu çalışmada, güvenlik kamerası sistemlerinde gerçek zamanlı silah tespiti için dört farklı derin öğrenme modeli (YOLOv11, RT-DETR, SSD-Lite + MobileNetV3-Large ve FCOS) karşılaştırmalı olarak değerlendirilmiştir. 10.824 görüntüden oluşan birleştirilmiş veri seti üzerinde gerçekleştirilen deneyler, RT-DETR modelinin güvenlik odaklı uygulamalar için en uygun seçenek olduğunu ortaya koymuştur.

Elde edilen sonuçlar literatürdeki çalışmalarla karşılaştırıldığında, Santos ve arkadaşları [6] tarafından yapılan sistematik derleme çalışmasında silah tespit alanında en yaygın kullanılan modellerin Faster R-CNN ve YOLO mimarileri olduğu tespit edilmiş ve mevcut yöntemlerin zorlu bağlamlarda sınırlı performans gösterdiği belirtilmiştir. Bu çalışmada elde edilen sonuçlar, transformer tabanlı RT-DETR modelinin geleneksel CNN tabanlı yaklaşımlara kıyasla zorlu koşullarda daha dayanıklı performans sergilediğini göstermektedir.

Wang ve arkadaşları [16] CCTV ortamlarında küçük nesne tespiti için optimize edilmiş YOLOv4 tabanlı bir sistem geliştirmişlerdir; çalışmamızda kullanılan RT-DETR modeli, transformer mimarisinin global bağlam modelleme yeteneği sayesinde küçük ve kısmi görünür nesnelerin tespitinde benzer avantajlar sunmakta olup, özellikle %99.7 Recall değeri Wang ve arkadaşlarının vurguladığı küçük nesne tespit probleminde etkin bir çözüm sağlamaktadır.

Yadav ve arkadaşları [17] düşük ışık koşullarında silah tespiti için YOLOv7-DarkVision modelini geliştirmiş ve %95.50 hassasiyet ile %93.41 F1-Skoru elde etmişlerdir. Bu çalışmada RT-DETR modeli

ile elde edilen %97.3 Precision ve ~%90 F1-Skoru değerleri, Yadav ve arkadaşlarının sonuçlarıyla karşılaştırılabilir düzeyde olup, veri setimizde bulunan gri tonlamalı ve düşük aydınlatmalı görüntüler üzerinde gerçekleştirilen testler RT-DETR modelinin değişken aydınlatma koşullarına adaptasyon yeteneğini doğrulamaktadır.

Berardini ve arkadaşları [18] video gözetim sistemlerinde gerçek zamanlı silah tespiti iyileştirmek amacıyla uç yapay zekâ (edge AI) tabanlı YOLOS modelini geliştirmiş ve YOLOv8'e kıyasla %10.2 oranında Ortalama Hassasiyet artışı sağlamıştır; bu çalışmada RT-DETR modelinin web kamerası üzerinden gerçek zamanlı testlerde sergilediği performans, benzer şekilde pratik uygulama senaryolarına yönelik optimize edilmiş bir çözüm sunmaktadır.

Lai ve Maples [19] tarafından gerçekleştirilen erken dönem çalışmada TensorFlow tabanlı OverFeat mimarisi kullanılarak %93 eğitim ve %89 test doğruluğu elde edilmiş, ancak araştırmacılar modelin çalışma süresinin gerçek zamanlı uygulamalar için sınırlayıcı olduğunu belirtmişlerdir. Bu çalışmada değerlendirilen RT-DETR modeli, hem yüksek doğruluk hem de gerçek zamanlı çıkarım hızı sunarak Lai ve Maples'in vurguladığı doğruluk-hız dengesini büyük ölçüde sağlamaktadır.

Mohamed ve arkadaşları [20] CCTV görüntülerinde ateşli silahların tespiti amacıyla AlexNet ve GoogLeNet mimarilerini kullanarak transfer öğrenme yaklaşımını uygulamışlardır. Buna karşın, sunulan çalışmada yalnızca CNN tabanlı mimarilerle sınırlı kalınmamış; transformer tabanlı (RT-DETR) ve CNN tabanlı (YOLOv11, SSD-Lite ve FCOS) nesne tespit modelleri birlikte değerlendirilerek, farklı mimari yaklaşımların silah tespiti problemindeki görece üstünlükleri analiz edilmiştir.

Çalışmadan elde edilen temel bulgular değerlendirildiğinde, RT-DETR modelinin %99.7 Recall değeri ile güvenlik uygulamaları açısından kritik olan tehditleri büyük ölçüde tespit edebildiği ve düşük kaçırma oranı sunduğu görülmektedir. YOLOv11 modeli %99.2 Precision ve %81.9 mAP@50:95 değerleri ile en yüksek kesinlik performansını sergilemiş olsa da gerçek zamanlı testlerde RT-DETR'nin gerisinde kalmıştır. SSD-Lite + MobileNetV3-Large kombinasyonu kaynak kısıtlı ortamlar için makul bir alternatif sunmakla birlikte %92.5 Recall değeri güvenlik uygulamaları için yeterli görülmemektedir. FCOS modeli ise anchor-free yaklaşımına rağmen diğer modellere kıyasla düşük performans sergilemiş olup, bu sonuç modelin silah tespit gibi spesifik problemler için ek optimizasyon gerektirdiğini göstermektedir.

Sonuç olarak, bu çalışma güvenlik kamerası sistemlerinde gerçek zamanlı silah tespiti için transformer tabanlı RT-DETR modelinin etkinliğini ortaya koymuştur. Elde edilen sonuçlar, RT-DETR'nin yüksek Recall değeri (%99.7) ve üstün gerçek zamanlı performansı ile güvenlik odaklı uygulamalar için ideal bir çözüm sunduğunu göstermektedir. Karmaşıklık matrisi analizi, modelin her iki sınıf (person ve weapon) için %92'nin üzerinde doğruluk oranlarına ulaştığını doğrulamakta olup, özellikle weapon sınıfı için elde edilen %92.5 doğruluk oranı güvenlik sistemlerinin temel gereksinimi olan silah tespiti konusunda yüksek güvenilirlik sağlamaktadır. Web kamerası üzerinden gerçekleştirilen canlı testler, RT-DETR modelinin değişken aydınlatma koşullarında ve farklı arka planlarda tutarlı tespit performansı sergilediğini kanıtlamış; modelin el işareti gibi silaha benzer nesnelere yanlış pozitif olarak sınıflandırılmaması pratik kullanımda güvenilirliğini artırmaktadır.

5. Kaynaklar (References)

- [1] S.A. Swanson, M. Miller, Toward a clearer understanding of what works to reduce gun violence: the role of falsification strategies, *Am. J. Epidemiol.* 193 (8) (2024) 1061–1065.
- [2] A. Yasuntimur, G.İ. Ögünç, Bireysel silahlanma ve şiddet: Ateşli silah şiddetinin güncel durumu, *Güvenlik Bilimleri Dergisi* 11 (1) (2022) 167–200.
- [3] İçişleri Bakanlığı, İçişleri Bakanımız Sayın Ali Yerlikaya, TBMM Genel Kurulu 2025 Bütçe Görüşmelerine katıldı [Basın Açıklaması], T.C. İçişleri Bakanlığı, 2024. Available from: <https://icisleri.gov.tr/icisleri-bakanimiz-sayin-ali-yerlikaya-tbmm-genel-kurulunda-yapilan-butce-gorusmelerinde-konustu>.

- [4] P. Aggarwal, S. Thapliyal, C.R. Singh, V. Kukreja, S. Mehta, Advanced computational approaches to gun detection with CNN-SVM model, in: Proceedings of the 5th International Conference for Emerging Technology, INCET 2024, IEEE, 2024, pp. 1–6.
- [5] Centers for Disease Control and Prevention, Fast facts: firearm injury and death, U.S. Department of Health & Human Services, 2024. Available from: <https://www.cdc.gov/firearm-violence/data-research/facts-stats/index.html>.
- [6] T. Santos, H. Oliveira, A. Cunha, Systematic review on weapon detection in surveillance footage through deep learning, *Comput. Sci. Rev.* 51 (2024) 100612.
- [7] S. Kan, Building Layered Defenses to Reduce Illegal Gun Violence, *Ark. L. Rev.* 78 (2025) 55.
- [8] N.U. Akıncıoğlu, Akıllı şehirlerde önleyici güvenlik: Sensör ağları ve CCTV'nin etkinliği üzerine nitel bir değerlendirme, *İDEALKENT* (50) (2025) 469–496.
- [9] F. Bahar, Küresel güvenlik tedbirleri. Gözetleme olgusu bağlamında özel güvenlik ve mobese kameraları, 2022.
- [10] P. Vennam, P. TC, T. BM, Y.G. Kim, P.K. BN, Attacks and preventive measures on video surveillance systems: A review, *Appl. Sci.* 11 (12) (2021) 5571.
- [11] D.M. Wood, K. Ball, D. Lyon, C. Norris, C. Raab, A report on the surveillance society, Surveillance Studies Network, UK, 2006, pp. 1–98.
- [12] A.H. Ashraf, M. Imran, A.M. Qahtani, A. Alsufyani, O. Almutiry, A. Mahmood, et al., Weapons detection for security and video surveillance using cnn and YOLO-v5s, *CMC-Comput. Mater. Contin.* 70 (4) (2022) 2761–2775.
- [13] Cumhurbaşkanlığı Dijital Dönüşüm Ofisi, Ulusal Yapay Zeka Stratejisi 2021-2025, T.C. Resmî Gazete (Sayı: 31574), 2021. Available from: <https://cbddo.gov.tr/uyzs>.
- [14] Anadolu Ajansı, Türkiye'nin İlk Ulusal Yapay Zeka Stratejisi açıklandı, Anadolu Ajansı, 2021. Available from: <https://www.aa.com.tr/tr/bilim-teknoloji/turkiyenin-ilk-ulusal-yapay-zeka-stratejisi-aciklandi/2344314>.
- [15] TÜBİTAK, Yapay Zeka Ekosistem Çağrısı - 2024 (1711-YZE-2024), 2024. Available from: <https://tubitak.gov.tr>.
- [16] G. Wang, H. Ding, M. Duan, Y. Pu, Z. Yang, H. Li, Fighting against terrorism: A real-time CCTV autonomous weapons detection based on improved YOLO v4, *Digit. Signal Process.* 132 (2023) 103790.
- [17] P. Yadav, N. Gupta, P.K. Sharma, Robust weapon detection in dark environments using Yolov7-DarkVision, *Digit. Signal Process.* 145 (2024) 104342.
- [18] D. Berardini, L. Migliorelli, A. Galdelli, M.J. Marín-Jiménez, Edge artificial intelligence and super-resolution for enhanced weapon detection in video surveillance, *Eng. Appl. Artif. Intell.* 140 (2025) 109684.
- [19] J. Lai, S. Maples, Developing a real-time gun detection classifier, Course: CS231n, Stanford University, 2017.
- [20] M.K. el den Mohamed, A. Taha, H.H. Zayed, Automatic gun detection approach for video surveillance, *Int. J. Sociotechnology Knowl. Dev.* 12 (1) (2020) 49–66.
- [21] Roboflow, Person-Weapon Datasets Computer Vision Model, Roboflow Universe, 2024. Available from: <https://universe.roboflow.com/school-fin7c/person-weapon-datasets>.
- [22] Instituto Superior de Engenharia de Coimbra, Gun Surveillance Computer Vision Model, Roboflow Universe, 2024. Available from: <https://universe.roboflow.com/instituto-superior-de-engenharia-de-coimbra-bgn4r/gun-surveillance>.
- [23] PU-SCBFP, Weapon Dataset, Roboflow, 2024. Available from: <https://app.roboflow.com/pu-scbfp/weapon-ojmsr-7ly42/>.
- [24] Ultralytics, YOLOv11: State-of-the-art real-time object detection, 2024. Available from: <https://docs.ultralytics.com/models/yolo11/>.

- [25] R. Khanam, M. Hussain, Yolov11: An overview of the key architectural enhancements, arXiv preprint, arXiv:2410.17725 (2024).
- [26] Y. Zhao, W. Lv, S. Xu, J. Wei, G. Wang, Q. Dang, et al., Detsr beat yolos on real-time object detection, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2024, 2024, pp. 16965–16974.
- [27] A. Howard, M. Sandler, G. Chu, L.C. Chen, B. Chen, M. Tan, et al., Searching for mobilenetv3, in: Proceedings of the IEEE/CVF International Conference on Computer Vision, ICCV 2019, 2019, pp. 1314–1324.
- [28] Z. Tian, C. Shen, H. Chen, T. He, Fcos: Fully convolutional one-stage object detection, in: Proceedings of the IEEE/CVF International Conference on Computer Vision, ICCV 2019, 2019, pp. 9627–9636.