



Güvenlik Kameralarında Otomatik Silah ve Bıçak Tespit Sistemi: Karşılaştırmalı YOLO Modelleri*

Mehmet Tevfik Ağdaş^{1†}, Sevinç Gülseçen²

¹Enformatik Anabilim Dalı, Fen Bilimleri Enstitüsü, İstanbul Üniversitesi, İstanbul, Türkiye, (ORCID: 0000-0002-5608-6240), m.agdas@ogr.iu.edu.tr

²Enformatik Anabilim Dalı, İstanbul Üniversitesi, İstanbul, Türkiye, (ORCID: 0000-0001-8537-7111), gulsecen@istanbul.edu.tr

(İlk Geliş Tarihi 18 Ağustos 2022 ve Kabul Tarihi 8 Ekim 2022)

(DOI: 10.31590/ejosat.1163675)

ATIF/REFERENCE: Ağdaş, M.T., Gülseçen, S., (2022). Güvenlik Kameralarında Otomatik Silah ve Bıçak Tespit Sistemi: Karşılaştırmalı YOLO Modelleri. Avrupa Bilim ve Teknoloji Dergisi, (41), 16-22.

Öz

Güvenlik kamera sistemleri genellikle sosyal ve kamusal alanlarda güvenli ortam koşulları oluşturmak için kullanılmaktadır. Günümüz güvenlik kamerası sistemlerinde insan görüşü yerine yapay zeka tabanlı bilgisayar görüşünden yararlanılmaya başlanılmıştır. Bu çalışma da toplumsal ve kamusal alanlarda olabilecek silah ve bıçak görüntülerinin bilgisayarlı görüş ile görülüp tespit edilmesi amaçlanmaktadır. Çalışmada yöntem ve model olarak görüntü işleme teknolojisi ve genellikle literatürde oldukça başarılı sonuçlar elde edildiği bilgisinin mevcut olduğu YOLO algoritmaları kullanılmıştır. YOLO algoritmalarından YOLOv4, YOLOv5, YOLOR ve YOLOX modelleri kullanılmıştır. Çalışmada veri seti olarak 5078 görüntü kullanılmış ve bu görüntülerin 3000 adetini silah ve 2078 adetini bıçak görüntüleri oluşturmaktadır. Görüntüler kullanılarak gerçekleştirilecek deneysel çalışmalarda güvenilirliğin sağlanması için görüntülerin seçiciliğinin zor olması tercih edilmiştir. YOLO algoritmalarının karşılaştırmalı deneysel çalışmaları yapılmış ve sonuçları yayınlanmıştır. Görüntülerde silah ve bıçak tespitinde en başarılı sonuç %97,6 map@0,5 değeri ile YOLOR modelinde elde edilmiştir.

Anahtar Kelimeler: Silah Tespiti, Bıçak Tespiti, YOLO, Görüntü İşleme.

Automatic Weapon and Knife Detection System on Security Cameras: Comparative YOLO Models

Abstract

Security camera systems are generally used to create safe environmental conditions in social and public spaces. In today's security camera systems, artificial intelligence-based computer vision has started to be used instead of human vision. In this study, it is aimed to see and detect images of weapons and knives that may be in social and public spaces with computer vision. In the study, image processing technology and YOLO algorithms were used as methods and models, where there is generally information that quite successful results have been obtained in the literature. YOLOv4, YOLOv5, YOLOR and YOLOX models from YOLO algorithms were used. In the study, 5078 images were used as a data set and 3000 of these images are weapons and 2078 knife images. In order to ensure reliability in experimental studies to be performed using images, it was preferred that the selectivity of the images be difficult. Comparative experimental studies of YOLO algorithms have been conducted and their results have been published. The most successful result in detecting weapons and knives in the images was obtained with the YOLOR model with a map@0.5% value of 97.6.

Keywords: Weapons, Knife, YOLO, Image Processing.

* Bu makale çalışması, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Enformatik Programı, Prof. Dr. Sevinç GÜLSEÇEN danışmanlığında, Videolarda Derin Öğrenme Yaklaşımları ile Anormal Durum Tespiti ve Boyut İndirgeme Sistemi isimli doktora tezinden türetilmiştir.

† Sorumlu Yazar: mtagdas@munzur.edu.tr

1. Giriş

Silahlı terörizm, toplum üzerinde şiddet, sağlık, psikolojik ve ekonomik olumsuzluklara sebebiyet vermektedir. Silah, sadece ateşli silahları kapsamamakta her türlü insanlara ve diğer canlı cansız varlıklara zarar verici aletlerde bu sınıfta yer almaktadır. Her yıl binlerce insan silah terörüyle ölmektedir. Ayrıca silah kullanımı toplumların şekillenmesinde büyük öneme sahiptir. Silahların yaygın kullanılması toplumlarda çocuk yaşlarda psikolojik ruhsal travmalara neden olmaktadır. Çocukların ilerleyen yaşlarında kişilik bozukluğu veya silah özentisi gibi olumsuz sonuçlar gözlemlenmektedir. Toplumlarda silah kullanımının erken tespit edilmesi ve müdahale edilmesi bu tür insanlarda oluşabilecek yıkıcı etkilerin azaltılmasında faydalı olabileceği savunulmaktadır [1],[2].

Kamusal ve özel kişisel alanlarda güvenliğin sağlanması ve silahlı eylemlerin tespiti için kişiler genellikle güvenlik kameralarına ihtiyaç duymaktadır. Olası bir tehlike durumlarında önceden tespit edilmesi veya olan olaylara açıklık getirilmesi için güvenlik kamerası görüntüleri büyük öneme sahiptir. Güvenlik kamerası sistemlerinde görüntüler çoğu zaman insan görü özellikleri kullanılarak analiz edilmektedir. İnsanın duygusal bir varlık olması ve zaman zaman dikkat eksiklikleri olabilmesi sebebiyle bazı olayların anlık olarak takibinde güvenlik zaafiyetleri doğmaktadır. Son zamanlarda yapılan çalışmalar incelendiğinde, bu tarz görüntülerin incelenmesi ve karar verilmesi aşamasında insan görüşü yerine makine öğrenmesi alt yapılı bilgisayarlı görünümünün kullanılması daha başarılı sonuçlar verdiği gözlemlenmiştir [3-6].

Bu çalışmada, akıllı gözetim ve güvenlik kameralarının görüntülerinde otomatik silah ve bıçak tespiti çalışması hedeflenmektedir. Bu çalışmanın gerçekleşmesi için derin öğrenme tabanlı bilgisayarda görüntü işleme teknolojisine ihtiyaç duyulmaktadır. Bunun içinde daha önceleri yapılmış derin öğrenme tabanlı görüntü işleme modelleri incelenmiş ve önceden eğitilmiş derin öğrenme modellerinin başarılı sonuçlar verdiği gözlemlenmiştir. Literatür incelemesinde güncel ve çok başarılı sonuçlar veren derin öğrenme tabanlı Yolo modelleri örneklerinden bazıları incelenmiştir. Bunlardan bazıları;

Warsi vd. (2019) çalışmasında, YOLOv3 algoritması kullanarak silah algılaması çalışması yapmışlardır [7]. Narejo vd. (2021) çalışmasında, akıllı güvenlik sistemlerinde YOLOv3 algoritmasını kullanarak silah algılanması projesini yapmışlardır [8]. Ashraf vd. (2021) çalışmalarında, CNN ve YOLOv5 algoritmalarını kullanarak güvenlik ve video gözetim sistemlerinde silah algılanması uygulamasını yapmışlardır [9]. Akbulut ve Halaf (2021) çalışmalarında, YOLO algoritmaları ve OpenCV kütüphanelerini kullanarak akıllı silah tespiti uygulamasını yapmışlardır [10]. Duran-Vega vd. (2021) çalışmalarında, YOLOv5 algoritmalarını kullanarak videolarda gerçek zamanlı tabanca tespiti için yarı tekrarlayan sinir ağlarına dayanan bir zamansal YOLOv5 dedektörü uygulamasını yapmışlardır [11].

Çalışmada, akıllı güvenlik sistemleri ve güvenlik kameralarında otomatik silah ve bıçak görüntülerinin anlık olarak tespit edilmesi çalışması yapılacaktır. Bu çalışmada makine öğrenmesi temelli derin öğrenme temelli daha önceden milyonlarca ImageNet görüntüsü ile eğitilmiş YOLO algoritmaları kullanılacaktır. Çalışmada 5078 birbirine yakın

sayıda bıçak ve silah görüntü kullanılacaktır. YOLO algoritmalarından, YOLOv3, YOLOv4, YOLOv5, YOLOX ve YOLOR model türleri kullanılıp sonuçları karşılaştırmalı olarak sonuçlar kısmında paylaşılacaktır.

2. Materyal ve Metot

Bu çalışma, makine öğrenmesi temelli derin öğrenme tabanlı daha önceden milyonlarca ImageNet görüntüsüyle eğitilmiş YOLO algoritmalarından, YOLOv3, YOLOv4, YOLOv5, YOLOX ve YOLOR modelleri kullanılacaktır. Sistem uygulamaları için Darknet ve PyTorch kütüphanesinden ve Tesla P100 ekran kartı ve 16 gb ram bellek donanımlarından yararlanılmıştır.

2.1. YOLO Modelleri

Yolo, Joseph Redmon, Santosh Divvalai Ross Girshick ve Ali Farhadi'nin 2016 yılında tanıtması ve OpenCV'nin People Choice Ödülünü kazanması ile büyük beğeni toplayan bir bilgisayarlı görü ailesinin üyesidir. Yolo modeli, tek tek aşamalı ağ geçişlerinden farklı olarak ağı tek geçişinde hem nesne tanımlama hem de sınıflandırma işlemi yapabilmekte ve tek aşamalı detektör olarak çalışabilmektedir. Bu model, tek tek aşamalı modellere göre genellikle daha hızlı ve daha güvenilir doğruluk skorları vermektedir [12].

Yolo algoritması modeli milyonlarca resim üzerinden eğitilmiş bir ağa sahiptir. Her geçen gün geliştiricileri tarafından bu ağ daha da büyütülmüş ve bu büyütülme aşamalarında farklı matematiksel algoritmalarla farklı hızlarda çalışabilecek sürümler ortaya çıkarılmıştır. Bu sürümler sırasıyla YOLO, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOX ve YOLOR şeklinde olmuştur. Literatür çalışmaları incelendiğinde en yaygın kullanılan versiyonların YOLOv3, YOLOv4, YOLOv5 oldukları gözlemlenmiştir. Bu modellerden oldukça başarılı sonuçlar alınabildiği gözlemlenmiştir. Bu çalışmada da yaygın olarak kullanılan versiyonlardan YOLOv4 ve YOLOv5 versiyonları ve yeni henüz az kullanılmış olan önceki versiyonlardan daha hızlı oldukları iddia edilen YOLOX ve YOLOR versiyonları da kullanılması hedeflenmiştir.

2.1.1. YOLOv4

YOLOv4 modeli, darknet sinir ağı çerçevesinde oluşturulmuş bir nesne tespiti algoritmasıdır. YOLOv4, hızlı ve başarılı sonuçlar vermesi nedeniyle bir çok uygulamada kullanılmaktadır. Derin evrişimli sinir ağlarını kullanarak nesnelere tespit edebilmekte ve ayrıca kutucuklar içerisinde göstermektedir. Veriler eğitilip YOLOv4 ağına aktarılmasından sonra görüntüler üzerindeki nesnelere hangi sınıfa ait olduğunu göstermektedir. Bu işlem sonucunda bir güven skoru oluşturmaktadır. Güven skoru, tahmin doğruluğunu göstermektedir. Güven skoru 0 ile 1 arasında olmaktadır [13]. Güven skorunun ölçümü için görüntünün örtüşme ölçütü olan IoU (Intersection over Union) değerinin bilinmesi gerekmektedir. Görüntüler üzerinde analizler yapılırken görüntülerin en dip pikselinden başlanmak üzere kesitler alınır ve kesitlerin bütünü temsil ne kadar temsil ettiğinin belirlenmesi için IoU değerine bakılmaktadır. IoU değerinin hesaplanması formülü denklem (2) de, Güven skoru formülü denklem (1) de gösterilmiştir.

$$\text{Güven Skoru} = Pr(\text{Nesne}) * IoU \quad (1)$$

$$IoU = \frac{\text{Kesişim}(\text{Gerçek-Referans} \cap \text{Tahmin})}{\text{Birleşim}(\text{Gerçek-Referans} \cup \text{Tahmin})} \quad (2)$$



Şekil 1. Görüntü Kesişim Örtüşmesi (IoU)
(Figure 1. Intersection Over Union)

Şekil 1 de görüntüde kesişim örtüşmesi örneği gösterilmiştir. YOLOv4 modelinde görüntülerden alınan kesitin bütünü temsil etmesi oldukça önemlidir. Ayrıca YOLOv4 ağı, üç bölüme oluşmaktadır. Bu bölümler omurga, boyun ve kafadır. Omurga, farklı görüntüler üzerinden özellik çıkarıp işleyen evrimsel sinir ağı bölümüdür. YOLOv4’de alt yapı olarak CSPDarknet53 sinir ağı kullanılmaktadır [14]. Ayrıca omurga bölümü içinde Bag of Specials ve Bag of Freebies bölümleri bulunmaktadır. Bu bölümler verisetinin zenginleştirilmesi için kullanılmaktadır [13]. Boyun, nesnelerin farklı boyutlarda da algılanabilmesi için kullanılmaktadır. Kafa bölümü, YOLOv3 ile benzer yapıya sahip Dense Prediction katmanıdır. Kafa bölümünde nesnelerin koordinatlarını, etiketlerini ve güven skorunu içeren bir vektör oluşturulmaktadır. Ayrıca YOLOv4’te SAM, SPP, PANet ağlarında etkin olarak kullanılmaktadır [15],[16],[17].

2.1.2. YOLOv5

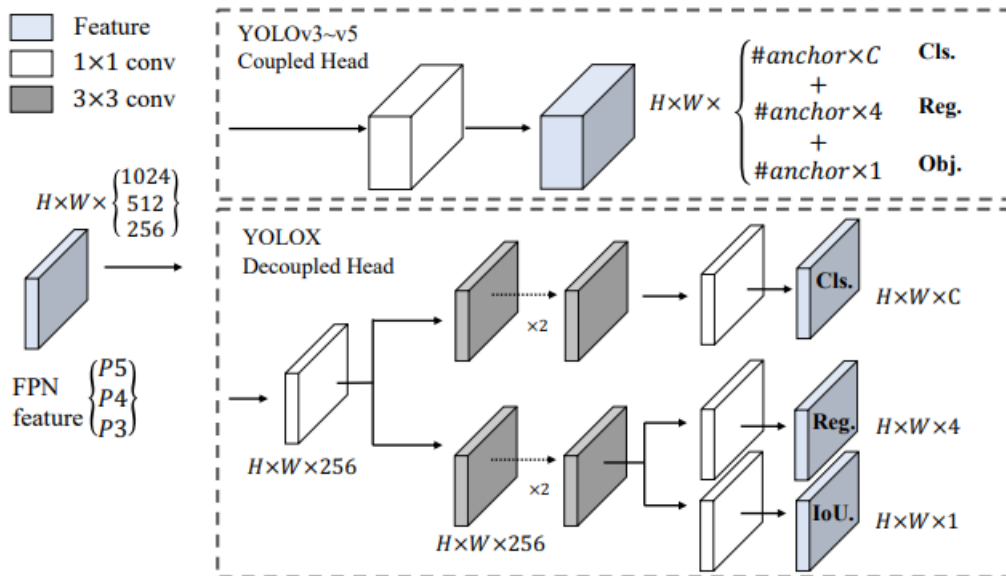
YOLOv5 modelinin mimarisinde de YOLOv4 modelinde olduğu gibi omurga, boyun ve kafa yapıları kullanılmıştır. Giriş görüntüleri omurga(backbone) yapısı sayesinde özellik çıkarma işlemine tabi tutulur. Omurga yapısı sayesinde elde edilen özellikler kullanılarak, bir özellik haritası oluşturulur. Özellik haritalarını kafa (head) yapılarına aktaran boyun (neck) aşağıdan yukarıya, yukarıdan aşağı yönünde bir kaç yoldan oluşmaktadır. Tek aşamalı nesne tespiti işlemlerinde kafa yapılarında yoğun bir şekilde güven skoru ve başarımları elde edilmektedir.

Darknet kütüphanesi üzerinde geliştirilen YOLOv4 algoritmasından farklı olarak YOLOv5 algoritması Pytorch Kütüphanesi kullanılarak geliştirilmiştir [18].

2.1.3. YOLOX

Yolox, ilk olarak Akış Algı Yarışması (CVPR2021) Otomatik Sürüş Workshop’unda tanıtılmıştır. Darknet alt yapısı kullanan bir modeldir. YOLOv4 ve YOLOv5 aşırı optimize edilmiş yapılar olduğundan bu yapıda YOLOv3-SPP ağ yapısı ile geliştirilmiştir. YoloV3-SPP, gelişmiş bir CSPNet omurgasını ve ek bir PAN kullanılmısinı benimseyerek YoloV5 mimarisi kullanılarak geliştirilmiş ağ yapısıdır [19].

Bu modelde, nesne algılama işlemlerinde çakışmalara neden olduğu bilinen ve doğruluğun azalmasına neden olan sınıflandırma ve regresyon görevleri aynı anda gerçekleştirilmektedir. Bu sorunun çözümü için ayrıştırılmış kafa yapısı oluşturulmuştur. Geleneksel yolo serilerinde omurga ve özellik piramitleri hala klasik kafa yapıları ile elde edilmektedir. Ancak Yolox modelinde ayrılmış bir kafa kullanılmış ve daha yüksek doğruluk skorları elde edilmesi hedeflenmiştir.



Şekil 2. YOLOX Modeli ile YOLOv3-v5 Modelinin Yapısı Arasındaki Fark
(Figure 2. The Difference Between the YOLOX Model and the Structure of the YOLOv3-v5 Model)

Yukarıdaki şekil2’de YOLOv3-v5 modellerinin yapısı ile YOLOX modelinin yapısı arasındaki fark gösterilmiştir. Her bir FPN seviyesi için özellik kanalının 256’ya dönüştürülmesi için önce 1x1 conv katmanı benimsenmiş ve iki paralel dal eklenmiştir. Sırasıyla sınıflandırma ve regrasyon görevleri için 3X3 dönüşüm katmanı eklenmiştir. Ayrıca regresyon dalına IoU dalı eklenmiştir [20].


YOLOX, Mozaik ve karıştırma stratejileri kullanılarak güçlü bir şekilde güçlendirilmiş bir veri seti üzerinde eğitilmiştir.

2.1.4. YOLOR

YOLOR, YOLOv5 modeline benzer şekilde Pytorch kütüphanesi kullanılarak geliştirilmiştir. CSPNet, doğruluk

skorları üzerinde azalmaya sebebiyet versede yolo modellerinde algılama hızını artırabilmek için yüksek verimli evrişimli katmanlar uygulamıştır. Scaled YOLOv4, kavramları alıp son teknoloji ürün bir detektör ailesine uygulamıştır.

Günümüzde yapay zeka eğitiminde kullanılan modeller, ağı önce genel bir görev için genel büyük veri seti ile eğitmekte sonra özel görevler için veri setlerini ince ayarlarla düzenlemektedir. Bu eğitim sırasında ince ayar işlemleri ile modelin ağırlıkları da ayarlanmaktadır. YOLOR, COCO veri setinde mevcut görevlerle, yani nesne algılama, örnek segmentasyonu, panoptic segmentasyon, anahtar nokta algılama, malzeme segmentasyonu, resim yazısı, çok etiketli görüntü sınıflandırması ve uzun kuyruk nesne tanıma ile örtük bir bilgi ağını önceden eğitmektedir [21].



Şekil 3. YOLOR Modelinin Çalışma Yapısı
(Figure 3. The Working Structure of the YOLOR Model)

Şekil 3’de YOLOR modelinin çalışma prensibi gösterilmektedir. YOLOR, COCO veri kümesini optimize ederken açık bilgiyi temsil edebilen başka bir parametre kümesini de eğitmektedir. Tahmin için ise hem örtük hem de açık bilgiyi kullanmaktadır [21].


2.2. Veri Seti

Bu çalışmada, daha önceleri çalışmalara kaynak olmuş veri seti kullanılmıştır. Veri seti iki ayrı nesne grubunu içermektedir. Bunlar silah ve bıçak verileridir. Silah verisinde zengin içeriğe sahip 3000 adet görüntü bulunmaktadır. Silah görüntüleri internet görüntüleri ve güvenlik kameralarından alınmıştır. Bu görüntüler daha önceleri Olmos vd. (2018), çalışmalarında kaynak olarak kullanılmıştır [22]. Bıçak verisi için ise 2078 adet görüntü kullanılmıştır. Bu görüntüler en az bir adet bıçak görüntüsü içermektedir. Bu görüntülerde internet ortamı, Youtube videoları

ve güvenlik kameraları görüntülerinden derlenmiştir. Bıçak görüntüleri seçilirlen bazı özellikler aranmıştır. Bu özellikler maddeler halinde aşağıda verilmiştir.

- Çeşitli tür, şekil, renk boyut ve farklı malzemeden yapılması
- Kameraların yakınında ve uzağında olması
- Bıçakların elle kısmen tutulmuş olması
- Bıçak görüntüsüne benzer çeldiricilerinde olması
- İç ve dış mekan görüntülerinde bıçak senaryolarının bulunmasına dikkat edilmiştir.

Bıçak veri setide daha önceleri Castillo vd. (2019), çalışmalarına kaynak veri olarak kullanılmıştır [23]. Kullanılan veri setine ait örnek görüntüler Resim 1. ve Resim2.’de verilmiştir. Resim 1 ve resim 2 de gösterildiği gibi görüntülerin her türlü açı ve bakış açısından olmasına dikkat edilmiştir.



Resim1. Örnek bıçak verileri görüntüleri (Picture 1. Sample knife data images)



Resim 2. Örnek silah verileri görüntüleri (Picture 2. Sample weapon data images)

Bıçak ve silah veri seti üzerinde ön işleme işlemleri yapılmış bazı görüntülerin açıları değiştirilerek görüntü sayısı artırılmıştır. Çalışma için kullanılan görüntü sayısı 9253 görüntü olarak kullanılmıştır. Bu görüntülerin 6600 adeti eğitim, 1000 adeti test ve 653-adet doğrulama verisi olarak kullanılmıştır.

3. Önerilen Metodoloji

Bu çalışmada, güvenlik kamerası görüntülerinde otomatik silah ve bıçak tespiti uygulaması yapılması hedeflenmiştir. Önerilen modelin seçiminde daha önceleri yapılan çalışmalar incelenmiştir. Literatürde YOLO modellerinin başarılı sonuçlar verdiği gözlenmiştir. Bu çalışmada da YOLO modellerinden en güncel ve en başarılı sonuçlar veren modellerden YOLOv4, YOLOv5, YOLOX ve YOLOR modelleri kullanılması çalışma

için metodoloji olarak önerilmiştir. Hem bu modellerin performansları arasındaki farklar gözlemlenecek hem de otomatik silah ve bıçak algılanması çalışması gerçekleştirilmiş olacaktır.

4. Analiz

Bu çalışmada güvenlik kamerası görüntülerinden otomatik silah ve bıçak algılanması için literatürdeki diğer çalışmalardan farklı olarak popüler ve başarılı sonuçlar veren daha önceden eğitilmiş model olan YOLO modelleri kullanılmış ve sonuçları karşılaştırılmıştır. YOLO modellerinden YOLOv4, YOLOv5, YOLOX ve YOLOR modelleri kullanılmıştır.

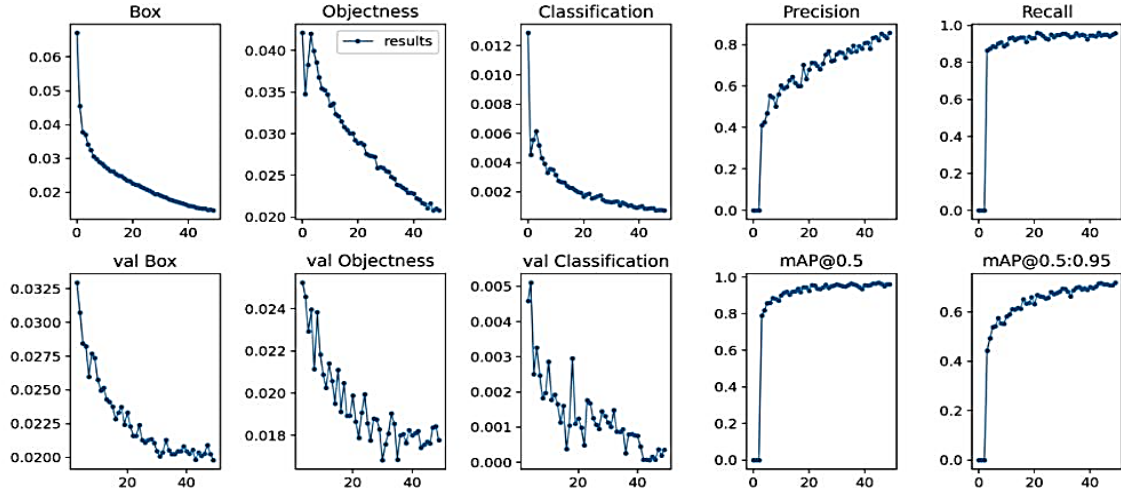
Karşılaştırma işleminin sağlıklı ve güvenilir olması için benzer Epoch, Batch ve Image Size değerleri seçilmiştir.

Tablo 1. Çalışmada elde edilmiş karşılaştırmalı yüzdesel skorlar (Table 1. Comparative percentage scores obtained in the study)

MODEL	BATCH	EPOCH	Image Size	Recall	Precision	Map@0,5
YOLOv4	8	50	416x416	0,91	0,90	0,9412
YOLOv5	8	50	416x416	0,816	0,86	0,864
YOLOX	8	50	416x416	0,89	0,894	0,9069
YOLOR	8	50	416x416	0,958	0,967	0,976

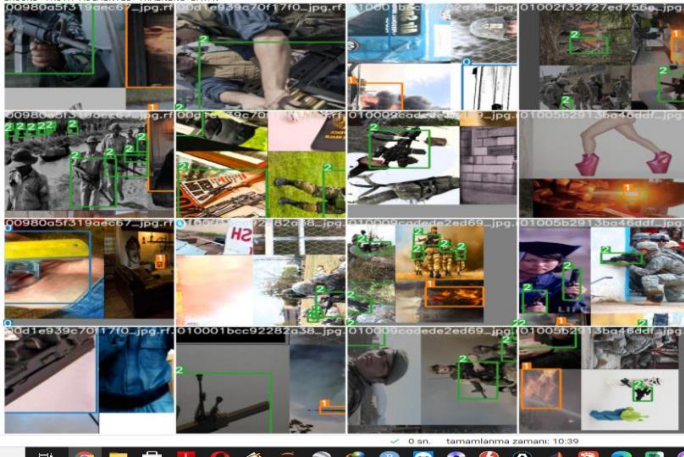
Çalışmada uygulanan modeller arasında en başarılı sonuçların YOLOR algoritmasının vermiş olduğu gözlemlenmiştir. YOLOR modeli çalışma süresi olarakta diğer modellere göre çok daha kısa sürede tamamlanmıştır. YOLOR

modeline göre silah ve bıçak tespiti işlemi sonuçları recall değeri 0,958, precision değeri 0,967 ve nesnelerin kesişiminin ortalama hassasiyet değeri olan Map@0,5 0,976 olarak hesaplanmıştır. YOLOR modelinde hesaplanan diğer değerlerde grafik halinde sonuçları da aşağıda verilmiştir.



Şekil 4. Deneysel çalışma analizlerinin grafiksel gösterimi
(Figure 4. Graphical representation of experimental study analyzes)

Görüntülerin analizler işlemleri neticesinde tespit edilmesine dair nesnel ve yüzdesel olarak sonuçlarının örnek görüntüleri resim 3 ve resim 4 te gösterilmiştir.



Resim 3. Örnek silah bıçak algılama nesnel
(Picture 3. Example weapon knife detection objective)



Resim 4. Örnek silah bıçak algılama yüzdesel
(Picture 4. Sample weapon knife detection percentage)

5. Sonuç

Bu çalışmada, görüntülerdeki silah ve bıçakların otomatik algılanması için güncel YOLO algoritmaları ile karşılaştırmalı deneysel çalışmalar yapılmıştır. Literatürde yaygın olarak kullanılan YOLOv3 modeli yerine daha güncel daha hızlı performans sonuçları veren YOLOv4, YOLOv5, YOLOX ve YOLOR modelleri tercih edilmiştir. Modellerin performanslarının doğruluğunun kıyaslanabilmesi için modellerde 8 batch, 50-epoch ve görüntülerin boyutlarının 416x416 ebatlarında olması sağlanmıştır. Çalışmada yapılan deneysel çalışmalar neticesinde modeller arasındaki en başarılı performansı % 95,8 recall, 0,967 Precision ve %97,6 Map@0,5 değerleri YOLOR algoritması ile elde edilmiştir. YOLOR algoritmasından sonra ise en başarılı sonuçlar sırasıyla daha önceki versiyon olmasına rağmen %94,12 map@0,5 başarımla YOLOv4 algoritmasından, %90,69 map@0,5 deęeriyle YOLOX ve %86,5 map@0,5 deęeriyle YOLOv5 algoritmasından elde edilmiştir.

Kaynakça

- [1] Velastin, S. A., Boghossian, B. A., & Vicencio-Silva, M. A. (2006). A motion-based image processing system for detecting potentially dangerous situations in underground railway stations. *Transportation Research Part C: Emerging Technologies*, 14(2), 96-113.
- [2] Bilgin, R. (2014). Çatışma Ve Şiddet Ortamında Büyüyen Çocuklar Sorunu. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 24(1), 135-152.
- [3] Kumar, P. M., Gandhi, U., Varatharajan, R., Manogaran, G., Jidhesh, R., & Vadivel, T. (2019). Intelligent face recognition and navigation system using neural learning for smart security in Internet of Things. *Cluster Computing*, 22(4), 7733-7744.

- [4] Babanne, V., Mahajan, N. S., Sharma, R. L., & Gargate, P. P. (2019, December). Machine learning based smart surveillance system. In *2019 Third International conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)* (pp. 84-86). IEEE.
- [5] Joshi, A., Jagdale, N., Gandhi, R., & Chaudhari, S. (2019, June). Smart surveillance system for detection of suspicious behaviour using machine learning. In *International Conference on Intelligent Computing, Information and Control Systems* (pp. 239-248). Springer, Cham.
- [6] Ko, K. E., & Sim, K. B. (2018). Deep convolutional framework for abnormal behavior detection in a smart surveillance system. *Engineering Applications of Artificial Intelligence*, 67, 226-234.
- [7] Warsi, A., Abdullah, M., Husen, M. N., Yahya, M., Khan, S., & Jawaid, N. (2019, August). Gun detection system using YOLOv3. In *2019 IEEE International Conference on Smart Instrumentation, Measurement and Application (ICSIMA)* (pp. 1-4). IEEE.
- [8] Narejo, S., Pandey, B., Rodriguez, C., & Anjum, M. R. (2021). Weapon Detection Using YOLO V3 for Smart Surveillance System. *Mathematical Problems in Engineering*, 2021.
- [9] Ashraf, A. H., Imran, M., Qahtani, A. M., Alsufyani, A., Almutiry, O., Mahmood, A., ... & Habib, M. (2022). Weapons Detection for Security and Video Surveillance Using CNN and YOLO-V5s. *CMC-COMPUTERS MATERIALS & CONTINUA*, 70(2), 2761-2775.
- [10] AKBULUT, Y., & KHALAF, R. Smart Arms Detection System Using YOLO Algorithm and OpenCV Libraries. *Turkish Journal of Science and Technology*, 16(1), 129-136.
- [11] Duran-Vega, M. A., Gonzalez-Mendoza, M., Chang-Fernandez, L., & Suarez-Ramirez, C. D. (2021). TYolov5: A Temporal Yolov5 Detector Based on Quasi-Recurrent Neural Networks for Real-Time Handgun Detection in Video. *arXiv preprint arXiv:2111.08867*.
- [12] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- [13] GÜÇLÜ, E., AYDIN, İ., ŞAHBAZ, K., Erhan, A. K. I. N., & KARAKÖSE, M. (2021). Demiryolu Bağlantı Elemanlarında Bulunan Kusurların YOLOv4 ve Bulanık Mantık Kullanarak Tespiti. *Demiryolu Mühendisliği*, (14), 249-262.
- [14] Wang, C. Y., Liao, H. Y. M., Wu, Y. H., Chen, P. Y., Hsieh, J. W., & 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* (pp. 390-391).
- [15] Woo, S., Park, J., Lee, J. Y., & Kweon, I. S. (2018). Cbam: Convolutional block attention module. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 3-19).
- [16] He, K., Zhang, X., Ren, S., & 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.
- [17] Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path aggregation network for instance segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8759-8768).
- [18] Murat, S. (2021). *İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma* (Master's thesis, Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü).
- [19] Zhang, S., Song, L., Liu, S., Ge, Z., Li, Z., He, X., & Sun, J. (2021). Workshop on Autonomous Driving at CVPR 2021: Technical Report for Streaming Perception Challenge. *arXiv preprint arXiv:2108.04230*.
- [20] Ge, Z., Liu, S., Wang, F., Li, Z., & Sun, J. (2021). Yolox: Exceeding yolo series in 2021. *arXiv preprint arXiv:2107.08430*.
- [21] Wang, C. Y., Yeh, I. H., & Liao, H. Y. M. (2021). You Only Learn One Representation: Unified Network for Multiple Tasks. *arXiv preprint arXiv:2105.04206*.
- [22] Olmos, R., Tabik, S., & Herrera, F. (2018) Automatic handgun detection alarm in videos using deep learning. *Neurocomputing*, 275, 66-72. doi.org/10.1016/j.neucom.2017.05.012.
- [23] Castillo, A., Tabik, S., Pérez, F., Olmos, R., Herrera, F. (2019) Brightness guided preprocessing for automatic cold steel weapon detection in surveillance videos using deep learning. *Neurocomputing*, 330, 151-161. doi.org/10.1016/j.neucom.2018.10.076.