

## Derin öğrenme tabanlı saklanan kamufle tankların tespiti: son teknoloji YOLO ağlarının karşılaştırmalı analizi

*Detection of hidden camouflaged tanks based on deep learning: comparative analysis of state-of-the-art YOLO networks*

Ahmet Furkan BAYRAM\*<sup>1</sup> , Vasif NABİYEYEV<sup>1</sup> 

<sup>1</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 61080, Trabzon

• Geliş tarihi / Received: 26.03.2023

• Kabul tarihi / Accepted: 18.09.2023

### Öz

Düşman hedeflerinin tespiti ve takibi, askeri operasyonlar için hayati öneme sahiptir. Bu çalışmada, kamufle tankların tespiti için derin öğrenme tekniklerinin kullanılması incelenmektedir. Bu çalışmanın temel amacı, ormanlık alanlarda gizlenmiş kamufle tankların tespit edilmesini sağlamaktır. Bu sayede, düşman hedeflerinin tespiti ve takibi daha etkili bir şekilde yapılabilmekte ve askerlerin güvenliği sağlanabilmektedir. YOLO mimarisi, nesne tespiti ve sınıflandırma işlemlerini tek bir ağda birleştirerek daha hızlı ve doğru sonuçlar elde etmeyi sağlamaktadır. YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 mimari tasarımları karşılaştırılmıştır. YOLOv6 mimari tasarımı, diğer tasarımlardan daha iyi performans göstermiştir. Bu tasarım, 2.234 adet tank görüntüsü ve 774 adet otomobil görüntüsü kullanılarak yapılan performans analizi sonucunda 0,983 mAP50 değerini, 0,966 kesinliği, 0,935 anma ve 0,950 F1 skorunu elde etmiştir. Bu çalışmanın sonuçları, farklı YOLO mimari tasarımlarının nesne tespiti ve sınıflandırma işlemlerinde yüksek performans elde ettiğini göstermektedir.

**Anahtar kelimeler:** Derin öğrenme, Kamufle tank tespiti, YOLOv6, Zırhlı araçlar

### Abstract

Detection and tracking of enemy targets is vital to military operations. In this study, the use of deep learning techniques to detect camouflaged tanks is examined. The main purpose of this study is to detect camouflaged tanks hidden in forest areas. In this way, the detection and tracking of enemy targets can be done more effectively and the security of the soldiers can be ensured. The YOLO architecture combines object detection and classification into a single network, resulting in faster and more accurate results. YOLOv5, YOLOv6, YOLOv7 and YOLOv8 architectural designs are compared. The YOLOv6 architectural design outperforms other designs. This design obtained 0,983 mAP50 value, 0,966 precision, 0,935 recall and 0,950 F1 score as a result of performance analysis using 2.234 tank images and 774 car images. The results of this study show that YOLO architectural designs show high performance in object detection and classification.

**Keywords:** Deep learning, Camouflage tank detection, YOLOv6, Armored vehicles

\*Ahmet Furkan BAYRAM; bayramahmet48@gmail.com

## 1. Giriş

### 1. Introduction

Gelişen teknoloji ve bilim, hayatın her alanında olduğu gibi askeri operasyonlarda da önemli değişikliklere sebep olmaktadır. Bu değişikliklerin en önemlisi, askeri operasyonlarda yapay zeka ve derin öğrenme tabanlı teknolojilerin kullanılmasıdır. Bu teknolojiler, askeri operasyonların etkinliğini ve hassasiyetini artırmakta, böylece askeri güçlerin stratejik avantajlar elde etmelerini sağlamaktadır. Bu çalışma, derin öğrenme tabanlı teknolojilerin, kamufle tankların tespiti gibi stratejik öneme sahip bir görevdeki faydasını araştırmaktadır. Bu araştırma, askeri operasyonların daha etkin ve hassas bir şekilde gerçekleştirilmesine katkı sağlayacaktır.

Bilgisayarla görme, yapay zeka ve makine öğrenimi gibi alanlardaki hızlı gelişmeler, belirli hedeflerin tespiti gibi zorlu görevleri gerçekleştirmek için yenilikçi teknolojilerin geliştirilmesine olanak sağlamıştır. Bu teknolojiler, askeri amaçlar dahil birçok alanda kullanılabilir. Özellikle, askeri alanda düşman hedeflerinin tespiti, tanıma ve takibi gibi konuların önemi oldukça yüksektir. Bu konular, askeri güçlerin konuşlanma dinamiklerine hakim olmaları, düşman hedeflerine hassas vuruş yapabilmeleri ve stratejik avantajlar elde edebilmeleri açısından büyük önem taşımaktadır.

Ancak ormanda saklanan kamufle olmuş tankların tespiti gibi konular, bilgisayarla görme araştırmaları alanında oldukça zorlu bir konudur. Orman ortamı, kamufleli araçların görünürlüğünü azaltmak için tasarlanmıştır ve bu nedenle görüntüdeki arka planın karmaşıklığı ve zırhlı araçların şekil ve boyutları gibi faktörler, tespit algoritmaları için büyük zorluklar oluşturmaktadır.

Bu zorlukların üstesinden gelmek için, You Only Look Once (YOLO) gibi tespit algoritmaları geliştirilmiştir. YOLO yöntemi, görüntüdeki birden fazla nesnenin tespit edilmesini sağlamaktadır. Bu yöntem, konvolüsyon sinir ağları (CNN) kullanarak görüntüdeki nesnelere birbirinden ayırt etmektedir. YOLO, görüntüyü küçük parçalara bölmekte, bu parçaları CNN ile tarar ve nesne olarak tanımlanabilecek herhangi bir özellik bulunması durumunda parçayı işaretlemektedir. Bu işaretlenen parçalar birleştirilerek ortaya çıkan alanlar nesnenin yer aldığı bölgeler olarak tanımlanmaktadır.

YOLO yöntemi, ormanda saklanan kamufleli tankların tespiti için oldukça etkili bir yöntemdir. Bu yöntem, görüntüdeki arka planın karmaşıklığına ve zırhlı araçların şekil ve boyutlarına rağmen, aracın görüntüsünde belirli özellikleri tespit ederek nesneyi işaretlemektedir. YOLO algoritması, hızlı ve doğru bir şekilde çalışmakta ve diğer tespit algoritmalarına göre daha yüksek doğruluk oranları sunmaktadır (Liu et al., 2021).

Bu çalışmada, YOLO tespit algoritmasının güncel sürümlerinin bu sorunun çözümüne katkısı araştırılmıştır. Çalışmanın temel amacı, ormanda saklanan kamufle olmuş tankların tespitini yaparak zaman kazanmak ve hata oranını en aza indirmektir.

Önerilen bu çalışmanın katkıları şu şekilde özetlenmiştir:

1. Açık kaynaklı bir veri seti, tank ve otomobil olarak iki sınıfta etiketlenmiştir.
2. Askeri operasyonlarda yapılan sistemin kullanılabilirliği araştırılmıştır.
3. Son teknoloji YOLO algoritmalarının karşılaştırılmalı analizi gerçekleştirilmiştir.

Makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2’de, muharebe araçlarının tespiti için saptamaya dayalı ilgili araştırmalar rapor edilmiştir. Bölüm 3’te, kullanılan metodolojiler detaylandırılmıştır. 4. bölümde elde edilen sonuçlar tartışılmıştır. Bölüm 5’te, elde edilen sonuçlar rapor edilmiştir.

## 2. İlgili çalışmalar

### 2. Related works

Bu bölümde, askeri ve askeri olmayan araçlar için çeşitli saptama teknikleri ile ilgili literatürdeki başlıca çalışmalar sunulmuştur.

Xiaozhu ve He (Xie & He, 2017), savaş ortamında bulunan zırhlı araçların tespitini gerçekleştirmeyi amaçlamışlardır. Yaptıkları bu çalışmada 7.000 adet tank ve tekerlekli muharebe aracı içeren bir veri seti kullanılmıştır. İlgili veri setindeki sınıfların tespiti işlemi için Faster R-CNN tabanlı derin öğrenme ağ

kullanılmıştır. Yapılan çalışmada tank sınıfı için %97,20 tespit oranı ve %89,60 tanıma oranı; tekerlekli muharebe aracı sınıfı için ise %96,70 tespit oranı ve %88,90 tanıma oranı elde edilmiştir.

Böyük vd. (Boyuk vd., 2020), gerçekleştirdikleri çalışmada insansız hava aracından alınan görüntüler ile araç tespiti yapmayı amaçlamışlardır. Model geliştirme aşamasında Stanford ve PSU veri setinde bulunan toplam 8.776 görüntü kullanılmıştır. Araç nesnelerin tespiti için Faster R-CNN, YOLOv3-Tiny ve SSD (single shot detector) algoritmaları analiz edilmiştir. Yapılan çalışmada Faster R-CNN, SSD ve YOLOv3-Tiny sırasıyla %75,16, %52,80 ve %56,20 mAP (mean average precision) değerlerini elde etmiştir.

Kamran vd. (Kamran vd., 2019), gerçekleştirdikleri çalışmada havadan alınan görüntülerle askeri araç ile sivil araçların tespitini gerçekleştirmişlerdir. Yapılan tespit işlemi için kullanılan veri seti taraflarınca hazırlanmış olup 15.086 görüntü içermektedir. İlgili nesnelerin tespiti için Faster R-CNN, R-FCN ve SSD algoritmaları kullanılmıştır. Faster R-CNN algoritması askeri araba için %62,79, sivil araba için %58,88 ve araç olmayan nesnelere için %60,72 mAP değerleri ile en iyi sonucu vermiştir.

Gupta vd. (Gupta vd., 2022), gerçekleştirdikleri çalışmada havadan alınan görüntülerle askeri kamyonlar, askeri tanklar, askeri uçaklar, askeri helikopterler, sivil araba ve sivil hava araçları sınıflarının tespitini amaçlamışlardır. Bu çalışma için kendilerince oluşturulan 6.772 görsel içeren veri seti kullanılmıştır. İlgili nesnelerin tespiti için Quantize SSD Mobilenet v2 ve YOLOv3 Tiny derin öğrenme modelleri kullanılmıştır. Yapılan araştırmada elde edilen gözlemler ve sonuçlara göre, YOLOv3 Tiny'nin diğer modele göre iyi performans gösterdiğini ayrıca oldukça verimli ve hafif olması nedeniyle uç tabanlı cihazlarla bile çalışabileceğini göstermiştir. YOLOv3 Tiny algoritması %79 hassaslık, %76 anma ve %77 F1 Skor değerini elde etmiştir.

Kyrkou vd. (Kyrkou vd., 2018), gerçekleştirdikleri çalışmada bir İHA (insansız hava aracı) kullanarak araç tespiti için tek atışlı CNN dedektörleri kullanılmıştır. Eğitim aşamaları, evrişimli bir sinir ağı mimarisi ile birlikte verimli bir şekilde haritalaması için gerekli optimizasyonlar tasarlanmıştır. YOLO algoritmasının, YOLOv3 Tiny, TinyYOLOVoc, TinyYOLONet ve DroNet olmak üzere dört farklı yapıyla uygulanmıştır. Dronet algoritması genel olarak %95 doğruluk sağlamakta ve saniyede 5-6 kare hızında çalışmaktadır.

Sun vd. (Sun vd., 2022), SAR teknolojinin gelişmesiyle birlikte, bu görüntüleri kullanarak askeri araçların tespitini amaçlamışlardır. Bu çalışmada BMP2, BTR70 ve T72 askeri araç türleri kullanılmıştır. İlgili nesnelerin tespiti için Faster RCNN, SSD300\_VGG16, SSD512\_VGG16, SSD\_ResNet\_SE\_Gaussian\_filter, YOLOv5, özelleştirilmiş YOLOv5, özelleştirilmiş YOLOv5 ile Transformer<sup>4</sup> ve özelleştirilmiş YOLOv5 ile Transformer<sup>6</sup> karşılaştırılmalı analizi gerçekleştirilmiştir. Özelleştirilmiş YOLOv5 algoritmasında neck-transformer yöntemi kullanılmıştır. Yapılan araştırmada elde edilen gözlemler ve sonuçlara göre, özelleştirilmiş YOLOv5 ile Transformer<sup>6</sup> %93,30 mAP değeri ile en iyi sonucu elde etmiştir.

Yong vd. (Yong & Yeong, 2018), gerçekleştirdikleri çalışmada drone görüntülerinden yararlanarak ormanda bulunan insan ve nesnelerin tespitini gerçekleştirmişlerdir. Nesne sınıflandırması için GoogleNet ve MobileNet mimarileri kullanılmıştır. Bu çalışma için kendilerince oluşturulan 650 insan ve 105 ağaç kesen araç görüntüsü içeren veri seti kullanılmıştır. Yapılan çalışmada %77,74 ortalama kesinlik, %77,39 ortalama anma ve %73,06 F-Skor değeri elde etmiştir.

Mansour vd. (Mansour vd., 2019), gerçekleştirdikleri çalışmada uydu görüntülerini kullanarak araç tespitini gerçekleştirmişlerdir. Uydu görüntülerinde araç gibi küçük nesnelerin tespiti arka planın karmaşıklığı, araç renkleri, uydu görüntüleri için büyük boyutlu olması sebebiyle zorlu bir görevdir. Bu görev için Inception-V2 tabanlı Faster R-CNN ve SSD tespit algoritmaları kullanılmıştır. Çalışmada Google Earth, JF-2 ve WORLDVIEW uydularından toplanan görüntüler kullanılmıştır. Eğitim için 324 görüntü ve test için 73 görüntüden oluşan toplam 8.447 araç etiketinden yararlanılmıştır. Gerçekleştirilen araştırmada elde edilen gözlemler ve sonuçlara göre, Faster R-CNN Inception V2 algoritması %89,21, SSD Inception V2 algoritması ise %84,21 mAP değeri ile daha yüksek başarı oranı elde etmiştir. Doğruluk değeri açısından Faster R-CNN Inception V2 algoritması daha yüksek değer elde etmesine rağmen SSD Inception V2 algoritmasından daha uzun sürede eğitim gerçekleştirmiştir.

**Tablo 1.** Literatürdeki diğer çalışmalarla karşılaştırma  
**Table 1.** Comparison with other studies in the literature

Yazarlar	Veri setleri	Görüntü adeti	Mimari	Sonuç
(Xie & He, 2017)	Kendi veri setini oluşturmuşlardır.	7.000	Faster R-CNN	%97,20 mAP
(Boyuk vd., 2020)	Standford ve PSU	8.776	Faster R-CNN	%75,16 mAP
(Kamran vd., 2019)	Kendi veri setini oluşturmuşlardır.	15.086	Faster R-CNN	%60,72 mAP
(Gupta vd., 2022)	Kendi veri setini oluşturmuşlardır.	6.772	YOLOv3-Tiny	%77,00 F1 Skor
(Kyrkou vd., 2018)	Kendi veri setini oluşturmuşlardır.	350	DroNet	%95,00 Doğruluk
(Sun vd., 2022)	MSTAR	32	YOLOv5-Transformer <sup>6</sup>	%93,30 mAP
(Yong & Yeong, 2018)	Kendi veri setini oluşturmuşlardır.	755	GoogleNet	%73,06 F1 Skor
(Mansour vd., 2019)	Kendi veri setini oluşturmuşlardır.	397	Faster R-CNN InceptionV2	%89,21 mAP
Bu çalışma	Özgün veri seti	3.008	YOLOv6	%98,30 mAP



**Şekil 1.** Veri setinde kullanılan örnek görseller  
**Figure 1.** Sample images used in the dataset

### 3.2. Veri ön işleme

#### 3.2. Data preprocessing

Görüntüler YOLO algoritmalarına girdi olarak verilmeden önce ön işleme adımları uygulanmıştır. Tüm görüntüler 640x640 boyutlarında yeniden ölçeklendirilmiştir. Son olarak, veri setindeki görüntülere ve 0 ile 1 aralığında ölçeklenen piksel değerlerine normalizasyon uygulanmıştır.

### 3.3. Tespit algoritmaları


#### 3.3. Detection Algorithms

Bu çalışmada ormanda saklanan kamuflejli takların tespitindeki performansları karşılaştırmak için YOLOv5 (Haque et al., 2022), YOLOv6 (Li vd., 2022), YOLOv7 (Wang vd., 2022) ve YOLOv8 (Reis et al., n.d.) mimarisi tasarımları kullanılmıştır.

YOLO mimarisi tasarımları, görüntüdeki bazı bölgeleri seçmek yerine, görüntüdeki bölgeleri algılamakta ve etrafına sınırlayıcı kutular çizmek için görüntünün tamamına bir sinir ağı uygulamaktadır. YOLO mimarilerinin tasarımları, girdi görüntüsünü  $S \times S$  ızgaralara bölen tek bir derin evrişimli sinir ağıdır. Her ızgara alanı, güven derecesine karşılık gelen ortalanmış hedef sınırlama kutusunu tahmin etmekten sorumludur. Her ızgara hücresi olasılık sınırlarını tahmin edilmektedir. Güven oranını veren formüle denklem (1)'de yer verilmiştir.

$$\text{Güven oranı} = pr(\text{sınıf}|\text{nesne}).pr(\text{nesne}).IoU = pr(\text{sınıf}).IoU \quad (1)$$

Mimari tasarımlar, bu ızgarada istenen herhangi bir nesnenin olup olmadığını bildiren ilişkili bir vektöre sahiptir. Öte yandan, bu modeller aşamalı yapısından dolayı zaman içinde daha iyi öğrenmekte ve daha doğru sonuçlar vermektedir. Bu tasarımların çalışma mekanizması, ilgili bölgede tespit edilen objeler içerisinde doğruluk oranı en yüksek olan objenin korunmasına dayalıdır.



Şekil 2. YOLO mimarisinin akış diyagramı

Figure 2. Flowchart of YOLO architecture

YOLOv5 nesne algılama algoritması, tek aşamalı bir çapa tabanlı (anchor-based) nesne algılama yöntemidir ve CSPNet (cross stage partial network), PANet (pyramid attention network) ve FPN (feature pyramid network) gibi özellikleri içeren bir mimariye sahiptir. YOLO katmanı ile çok ölçekli nesne tahmini yapılabilmekte ve Pascal VOC ve Microsoft COCO gibi veri kümelerinde başarılı sonuçlar elde edilebilmektedir. YOLOv5, eğitim sırasında parametre sayısını azaltarak hız ve doğruluk artışı sağlayabilen CSPNet kullanmaktadır. Ayrıca yol toplama ağı (PANet) gibi mimari özellikler, bilgi aktarımının verimliliğini artırmaktadır. FPN özelliği alt katmanlardan özellik aktarımına odaklanarak nesne yerleştirme görevlerini iyileştirmektedir (Haque et al., 2022).

YOLOv6, daha fazla özellik haritası ve daha fazla sınıflandırma katmanı kullanarak mAP oranını artırmayı başarmıştır. Ayrıca daha fazla çapa kutusu ve daha fazla özellik haritası kullanımı sayesinde daha fazla nesne tespit etmiştir. YOLOv7 ise bu özellikleri daha da genişleterek, özellik haritalarını ve sınıflandırma katmanlarını artırarak nesne algılama kabiliyetini daha da geliştirmiştir (Li vd., 2022).

YOLO serisinin en son versiyonu olan YOLOv8, bir dizi önemli yenilik getirmiştir. Yeni bir mimari tasarıma sahip olan YOLOv8, FPN ve PAN modüllerini birleştirmektedir. FPN, giriş görüntüsünün çözünürlüğünü kademeli olarak azaltırken özellik kanallarının sayısını artırmaktadır. Bu, farklı ölçeklerde ve çözünürlüklerde nesnelere algılayabilen özellik haritalarının oluşturulmasını sağlamaktadır. PAN mimarisi, ağı farklı seviyelerinden özellikleri toplayarak, farklı boyut ve şekillerdeki nesnelere doğru bir şekilde algılama yeteneğini artırmaktadır (Reis et al., n.d.).

YOLOv8, önceki versiyonlarına göre daha gelişmiş son işlem teknikleriyle donatılmıştır. Sinir ağı tarafından üretilen tahmini sınırlayıcı kutular ve nesne skorları üzerinde uygulanan bu teknikler, algılama sonuçlarını rafine etmekte, gereksiz algılamaları kaldırmakta ve tahminlerin genel doğruluğunu artırmaktadır. Bu teknikler arasında, YOLOv5'te kullanılan NMS (non-maximum suppression) tekniğinin bir varyantı olan Soft-NMS bulunmaktadır. Soft-NMS, örtüşen sınırlayıcı kutuları tamamen silmek yerine, onlara yumuşak bir eşik uygulamaktadır (Reis et al., n.d.).

YOLOv6 ve YOLOv7 algoritmaları yakın zamanda sırasıyla Haziran ve Temmuz 2022'de yayınlanmıştır. YOLOv6-L, COCO veri setinde %52.8'lik bir mAP değeri elde ederek mAP değeri %49 olan YOLOv5-L algoritmasını geride bırakmıştır. YOLOv8-L algoritması ise %52.9 değeri ile YOLOv6-L algoritmasını az bir farkla geride bırakmıştır. Tablo 2'de YOLO modelleri ile ilgili çoklu derinlik, çoklu genişlik, mAP, parametre sayısı ve FLOPs (floating point operations) değerlerine yer verilmiştir.

**Tablo 2.** YOLO modellerinin değerlerinin karşılaştırılması**Table 2.** Comparison of values of YOLO models

Model	Çoklu derinlik	Çoklu genişlik	mAP50-95	Parametre sayısı (M)	FLOPs (G)
YOLOv5	1,33	1,25	50,7	86,7	205,7
YOLOv6	1,0	1,0	52,8	59,6	150,7
YOLOv7	1,0	1,0	53,1	71,3	189,9
YOLOv8	1,0	1,25	53,9	68,2	257,8

### 3.4. Performans değerlendirme metrikleri

#### 3.4. Performance evaluation metrics

Çalışmada kullanılan modelin performansının analizi için mean average precision (mAP), kesinlik, anma ve F1 skor performans değerlendirme metriği kullanılmıştır.

**True Positive (TP):** Test sırasında elde edilen IoU (intersection over union) değeri 0,5'ten büyükse TP olarak değerlendirilmektedir.

**False Positive (FP):** Test sırasında elde edilen IoU değeri 0,5'ten küçükse veya sınırlayıcı kutular birden fazla oluşmuş ise FP olarak değerlendirilmektedir.

**False Negative (FN):** Nesne tespit edilmesi gereken durumda herhangi bir nesne tespit edilmediyse veya IoU değeri 0,5'ten büyükken sınıfı yanlış ise FN olarak değerlendirilmektedir.

TP, FP ve FN parametrelerinin kullanımı ile Kesinlik ve Anma parametreleri hesaplanmaktadır. Bu parametrelere ait formüller denklem (2), denklem (3) ve denklem (4)'de gösterilmiştir;

$$Kesinlik = \frac{TP}{TP + FP} \quad (2)$$

$$Anma = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ Skor = \frac{2 * Kesinlik * Anma}{Kesinlik + Anma} \quad (4)$$

## 4. Deneysel analizler

### 4. Experimental Analysis

YOLO mimarisi tasarımları için eğitim aşaması şu şekildedir:

Ağırlık güncellemeleri için Adam optimizyer, kayıp fonksiyonu olarak çapraz entropi kullanılmış ve öğrenme oranı 1e-3 olarak seçilmiştir. YOLO mimari tasarımları 50 epoch boyunca eğitilmiş ve parti boyutu 8 olarak belirlenmiştir. Deney sırasında ilgili modellerin önceden eğitilmiş modelleri kullanılarak öğrenme aktarımı yapılmıştır. Tüm deneyler PyTorch kütüphanesinde ve Google Colab entegre geliştirme ortamında (IDE) NVIDIA Tesla A100 ekran kartı kullanılarak gerçekleştirilmiştir.

Tablo 3, YOLOv5 ile elde edilen sonuçları göstermektedir. YOLOv5 ile tüm sınıfların ortalaması için %92,2 kesinlik, %94,1 anma, %93,1 F1 skor, %97,3 mAP50 ve %76,1 mAP50-95 değeri elde edilmiştir. Tank sınıfı için YOLOv5 ile %94,7 kesinlik, %93,5 anma, %94,1 F1 skor, %96,9 mAP50 ve %68,5 mAP50-95 değeri elde edilmiştir. Otomobil sınıfı için YOLOv5 ile %89,8 kesinlik, %94,7 anma, %92,1 F1 skor, %97,8 mAP50 ve %83,7 mAP50-95 değeri elde edilmiştir.

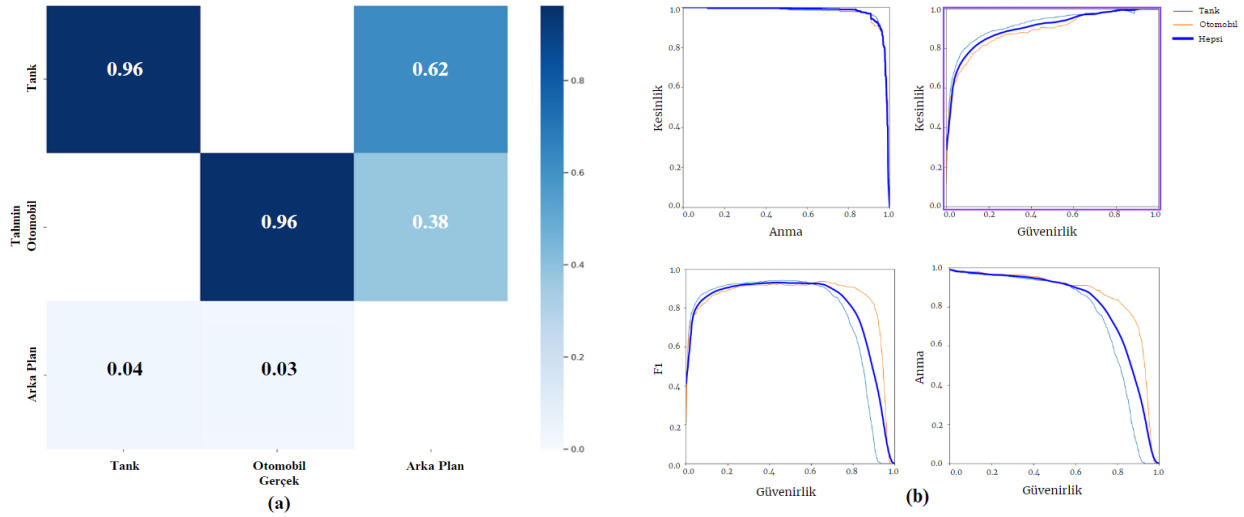
Karmaşıklık matrisi, eğitilen modelin iki farklı nesne sınıfı için nesne sınıflandırma görevi yapma performansını özetlemektedir. Her bir hücre, belirli bir gerçek ve tahmin sınıf çifti için gözlemlenen olay sayısını göstermektedir. Matrisin ana çaprazı gerçek sınıfların model tarafından doğru bir şekilde tahmin edildiği durumları temsil etmektedir.

Karmaşıklık matrisi analiz edildiğinde, eğitilen modellerin görüntülerde tank ve otomobillerin varlığını iyi bir doğruluk puanıyla tespit edebildiği görülmektedir. YOLOv5 kullanılarak eğitilen modelde, tank ve otomobil için sırasıyla %96 ve %96 doğruluk puanlarıyla ilgili nesnenin varlığını tespit edebilmektedir.

**Tablo 3.** YOLOv5 mimarisi ile doğrulama veri setinden elde edilen performans sonuçları

**Table 3.** Performance results from validation dataset with YOLOv5 architecture

Sınıf	Kesinlik	Anma	F1 skor	mAP50	mAP50-95
Hepsi	0,922	0,941	0,931	0,973	0,761
Tank	0,947	0,935	0,941	0,969	0,685
Otomobil	0,898	0,947	0,921	0,978	0,837



**Şekil 3.** (a) YOLOv5 tarafından elde edilen karmaşıklık matrisi (b) YOLOv5 modelinin algılama performansı ölçümleri

**Figure 3.** (a) The confusion matrix obtained by YOLOv5 (b) Detection performance measurements of the YOLOv5 model

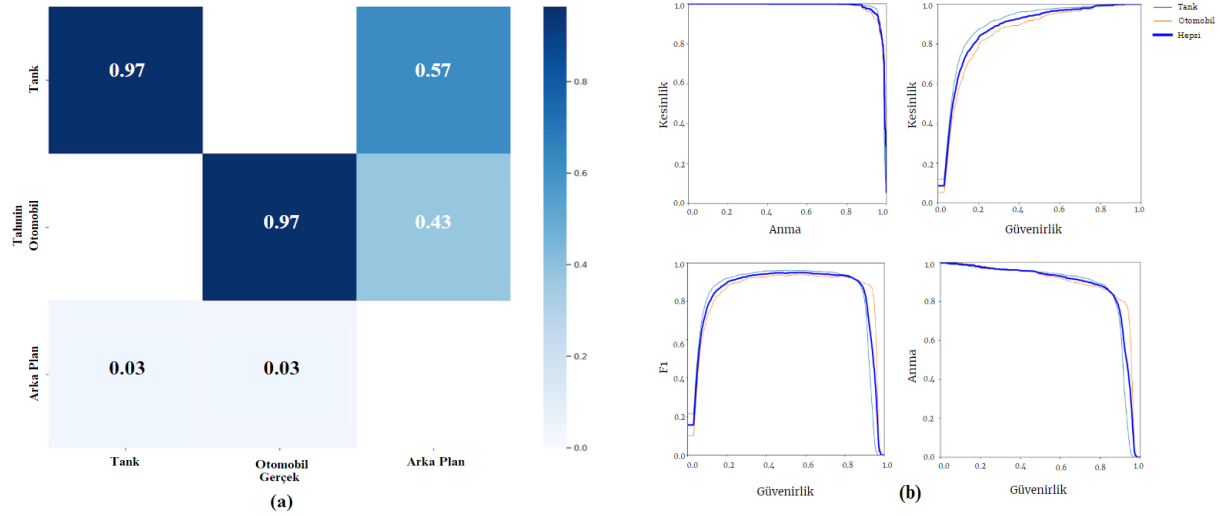
Tablo 4, YOLOv6 kullanılarak elde edilen sonuçları göstermektedir. YOLOv6 ile tüm sınıfların ortalaması için %96,6 kesinlik, %93,5 anma, %95 F1 skor, %98,3 mAP50 ve %79,4 mAP50-95 değeri elde edilmiştir. Tank sınıfı için YOLOv6 ile %97,9 kesinlik, %94,4 anma, %96,1 F1 skor, %98,2 mAP50 ve %72,7 mAP50-95 değeri elde edilmiştir. Otomobil sınıfı için YOLOv6 ile %95,4 kesinlik, %92,5 anma, %93,9 F1 skor, %98,4 mAP50 ve %86,1 mAP50-95 değeri elde edilmiştir.

YOLOv6 kullanılarak eğitilen modelde, tank ve otomobil için sırasıyla %97 ve %97 doğruluk puanlarıyla ilgili nesnenin varlığını tespit edebilmektedir. İlgili nesnelere tespit etme başarısının diğer tüm modellere göre daha yüksek olduğunu göstermektedir.

**Tablo 4.** YOLOv6 mimarisi ile doğrulama veri setinden elde edilen performans sonuçları

**Table 4.** Performance results from validation dataset with YOLOv6 architecture

Sınıf	Kesinlik	Anma	F1 skor	mAP50	mAP50-95
Hepsi	0,966	0,935	0,950	0,983	0,794
Tank	0,979	0,944	0,961	0,982	0,727
Otomobil	0,954	0,925	0,939	0,984	0,861



**Şekil 4.** (a) YOLOv6 tarafından elde edilen karmaşıklık matrisi (b) YOLOv6 modelinin algılama performansı ölçümleri

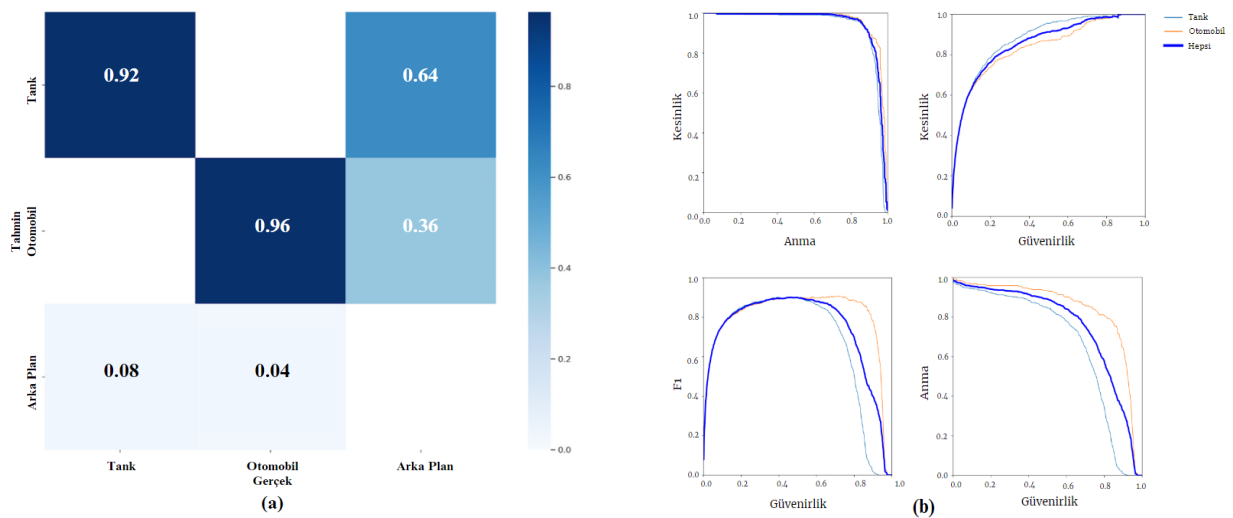
**Figure 4.** (a) The confusion matrix obtained by YOLOv6 (b) Detection performance measurements of the YOLOv6 model

Tablo 5, YOLOv7 kullanılarak elde edilen sonuçları göstermektedir. YOLOv7 ile tüm sınıfların ortalaması için %90,7 kesinlik, %89,8 anma, %90,2 F1 skor, %94,9 mAP50 ve %71,2 mAP50-95 değeri elde edilmiştir. Tank sınıfı için YOLOv7 ile %94,6 kesinlik, %85,9 anma, %90 F1 skor, %93,5 mAP50 ve %62,4 mAP50-95 değeri elde edilmiştir. Otomobil sınıfı için YOLOv7 ile %86,7 kesinlik, %93,8 anma, %90,1 F1 skor, %96,4 mAP50 ve %80,1 mAP50-95 değeri elde edilmiştir. YOLOv7 kullanılarak eğitilen modelde, tank ve otomobil için sırasıyla %92 ve %96 doğruluk puanlarıyla ilgili nesnenin varlığını tespit edebilmektedir.

**Tablo 5.** YOLOv7 mimarisi ile doğrulama veri setinden elde edilen performans sonuçları

**Table 5.** Performance results from validation dataset with YOLOv7 architecture

Sınıf	Kesinlik	Anma	F1 skor	mAP50	mAP50-95
Hepsi	0,907	0,898	0,902	0,949	0,712
Tank	0,946	0,859	0,900	0,935	0,624
Otomobil	0,867	0,938	0,901	0,964	0,801



**Şekil 5.** (a) YOLOv7 tarafından elde edilen karmaşıklık matrisi (b) YOLOv7 modelinin algılama performansı ölçümleri

**Figure 5.** (a) The confusion matrix obtained by YOLOv7 (b) Detection performance measurements of the YOLOv7 model

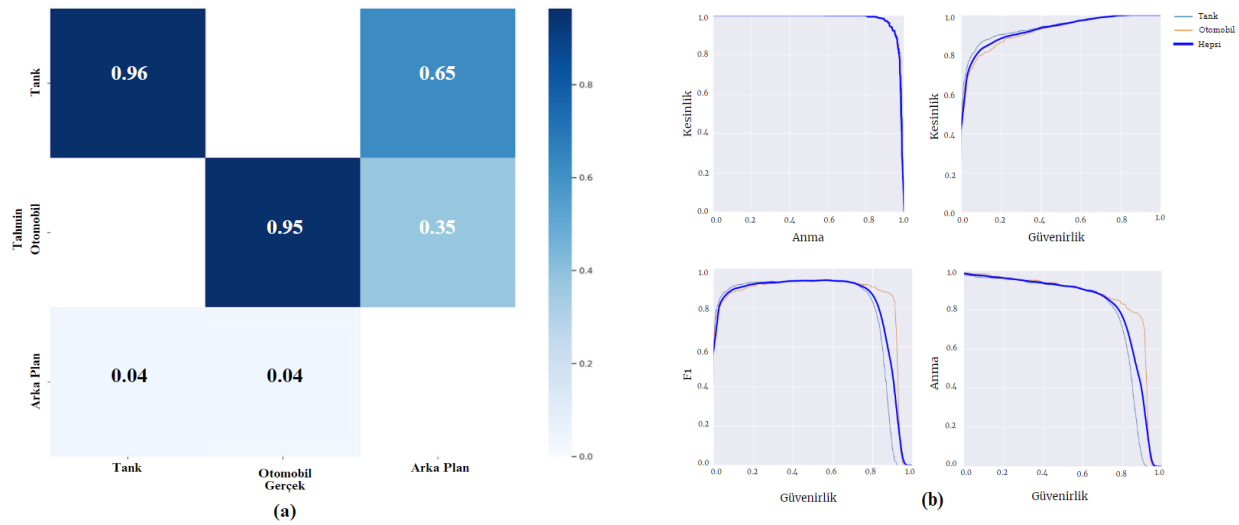


Tablo 6, YOLOv8 kullanılarak elde edilen sonuçları göstermektedir. YOLOv8 ile tüm sınıfların ortalaması için %97,9 kesinlik, %90,3 anma, %93,9 F1 skor, %97,7 mAP50 ve %78,8 mAP50-95 değeri elde edilmiştir. Tank sınıfı için YOLOv8 ile %97,2 kesinlik, %91,3 anma, %94,1 F1 skor, %97,3 mAP50 ve %71,7 mAP50-95 değeri elde edilmiştir. Otomobil sınıfı için YOLOv8 ile %98,6 kesinlik, %89,3 anma, %93,7 F1 skor, %98 mAP50 ve %85,9 mAP50-95 değeri elde edilmiştir. YOLOv8 kullanılarak eğitilen modelde, tank ve otomobil için sırasıyla %96 ve %96 doğruluk puanlarıyla ilgili nesnenin varlığını tespit edebilmektedir.

**Tablo 6.** YOLOv8 mimarisi ile doğrulama veri setinden elde edilen performans sonuçları

**Table 6.** Performance results from validation dataset with YOLOv8 architecture

Sınıf	Kesinlik	Anma	F1 skor	mAP50	mAP50-95
Hepsi	0,979	0,903	0,939	0,977	0,788
Tank	0,972	0,913	0,941	0,973	0,717
Otomobil	0,986	0,893	0,937	0,980	0,859



**Şekil 6.** (a) YOLOv8 tarafından elde edilen karmaşıklık matrisi (b) YOLOv8 modelinin algılama performansı ölçümleri

**Figure 6.** (a) The confusion matrix obtained by YOLOv8 (b) Detection performance measurements of the YOLOv8 model

Test örnekleri Şekil 7'de gösterilmektedir. YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 modellerinin eğitimi sonrasında elde edilen test sonuçlarının bazı örnekleri Şekil 8'de gösterilmektedir. Şekil 8'de YOLOv6 modelinin diğer modellere göre daha yüksek güven skoru ile nesneyi tahmin ettiği görülmektedir. YOLOv6 modeli aynı zamanda kamufle olmuş tankların tespitini ve kutu sınırlarını daha iyi bir şekilde belirlediği görülmektedir. Şekil 8'deki sonuçlar incelendiğinde, test verisindeki sol üstte yer alan görselde tankların hepsi YOLOv6 tarafından tespit edildiği görülmektedir. YOLOv7 modelinin sadece önde yer alan tankı, YOLOv5 ile YOLOv8 modelleri ise önde bulunan tankı ve arka kısımda bulunan üç tanktan sadece birini tespit edebilmiştir. Sağ üstteki görselde ağaçların arkasında bulunan tankı ise sadece YOLOv6 modelinin %60 güven skoru ile tespit edildiği görülmektedir. Sol altta yer alan görseli YOLOv6 modeli %80, YOLOv8 modeli ise %50 güven skoru ile tespit ettiğini, diğer modellerin ise tespit edemediği görülmektedir. Sağ altta bulunan görselde ise tamamen kamufle olan bir tankı YOLOv6 modeli %57 güven skoru ile tespit ederken YOLOv8 modeli ise %86 güven skoru ile tespit edilmiştir.



Şekil 7. Test Görüntüleri  
Figure 7. Test Images



Şekil 8. Test görüntülerinden elde edilen sonuçlar (a) YOLOv5 (b) YOLOv6 (c) YOLOv7 (d) YOLOv8  
Figure 8. Results from test images (a) YOLOv5 (b) YOLOv6 (c) YOLOv7 (d) YOLOv8

## 5. Sonuç

### 5. Conclusion

Bu çalışmada, YOLO tabanlı kamuflajlı tanklar için bilgisayar destekli tespit sistemi önerilmektedir. Bu bağlamda, yeni bir veri seti oluşturulmuştur. Bu veri seti üzerinde eğitim için YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 algoritmaları test edilmiştir. İlgili algoritmalarda Adam optimizör, kayıp fonksiyonu için çapraz entropi kullanılmış ve öğrenme oranı  $1e-3$  olarak ayarlanmıştır. En iyi tespit sonucunu 0,983 mAP50 değerini, 0,966 kesinlik, 0,935 anma ve 0,950 F1 skoru ile en yüksek değerleri ile YOLOv6 mimari tasarımı elde etmiştir. Bu çalışma, kamuflajlı tankların tespiti alanında yapılan ilk araştırma olduğundan dolayı, modelin

başarımı doğrudan bir karşılaştırmaya tabi tutulamamıştır. Bunun yerine, modelin potansiyel güçlü ve zayıf yönleri üzerinde durulmuştur. Sonuç olarak, kamuflajlı tankların tespitine yönelik olarak bilgisayarlı görü destekli bir karar destek mekanizması oluşturulmuştur. Gelecek çalışmalarda ise tespit edilen tankların gerçeklik sınıflandırma sistemi geliştirilecektir.

### **Yazar katkısı**

*Author contribution*

Yazarlar çalışmaya eşit oranda katkıda bulunmuştur.

### **Etik beyanı**

*Declaration of ethical code*

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve / veya yasal-özel izin gerektirmediğini beyan etmektedir.

### **Çıkar çatışması beyanı**

*Conflicts of interest*

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

### **Kaynaklar**

*References*

- Boyuk, M., Duvar, R., & Urhan, O. (2020). Deep learning based vehicle detection with images taken from unmanned air vehicle. *Proceedings 2020 Innovations in Intelligent Systems and Applications Conference, ASYU 2020*. <https://doi.org/10.1109/ASYU50717.2020.9259868>
- Gupta, P., Pareek, B., Singal, G., & Rao, D. V. (2022). Edge device based military vehicle detection and classification from UAV. *Multimedia Tools and Applications, 81*(14), 19813–19834. <https://doi.org/10.1007/S11042-021-11242-Y/FIGURES/12>
- Haque, E., Rahman, A., Junaid, I., Hoque, S. U., & Paul, M. (2022). Rice Leaf Disease Classification And Detection Using YOLOv5.
- Kaggle (t.y.). Military Tanks Dataset (Images). <https://www.kaggle.com/datasets/antoreepjana/military-tanks-dataset-images>
- Kaggle (t.y.). War Tank Images Dataset. <https://www.kaggle.com/datasets/icanerdogan/war-tank-images-dataset>
- Kamran, F., Shahzad, M., & Shafait, F. (2019). Automated military vehicle detection from low-altitude aerial images. *2018 International Conference on Digital Image Computing: Techniques and Applications, DICTA 2018*. <https://doi.org/10.1109/DICTA.2018.8615865>
- Kyrkou, C., Plastiras, G., Theocharides, T., Venieris, S. I., & Bouganis, C. S. (2018). DroNet: Efficient convolutional neural network detector for real-time UAV applications. *Proceedings of the 2018 Design, Automation and Test in Europe Conference and Exhibition, 967–972*. <https://doi.org/10.23919/DATE.2018.8342149>
- Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Ke, Z., Li, Q., Cheng, M., Nie, W., Li, Y., Zhang, B., Liang, Y., Zhou, L., Xu, X., Chu, X., Wei, X., & Wei, X. (2022). YOLOv6: A single-stage object detection framework for industrial applications. *Arxiv.Org*. <https://doi.org/10.48550/arxiv.2209.02976>
- Liu, K., Tang, H., He, S., Yu, Q., Xiong, Y., & Wang, N. (2021). Performance validation of YOLO variants for object detection. *Proceedings of the 2021 International Conference on Bioinformatics and Intelligent Computing, BIC 2021, 239–243*. <https://doi.org/10.1145/3448748.3448786>
- Mansour, A., Hassan, A., Hussein, W. M., & Said, E. (2019). Automated vehicle detection in satellite images using deep learning. *IOP Conference Series: Materials Science and Engineering, 610*(1). <https://doi.org/10.1088/1757-899X/610/1/012027>

- Reis, D., Kupec, J., Hong, J., & Daoudi, A. (n.d.). *Real-Time Flying Object Detection with YOLOv8*.
- Sun, Y., Wang, W., Zhang, Q., Ni, H., & Zhang, X. (2022). Improved YOLOv5 with transformer for large scene military vehicle detection on SAR image. *2022 7th International Conference on Image, Vision and Computing, ICIVC 2022*, 87–93. <https://doi.org/10.1109/ICIVC55077.2022.9887095>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Arxiv.Org*. <https://doi.org/10.48550/arxiv.2207.02696>
- Xie, X., & He, C. (2017). Object detection of armored vehicles based on deep learning in battlefield environment. *Proceedings - 2017 4th International Conference on Information Science and Control Engineering, ICISCE 2017*, 1568–1570. <https://doi.org/10.1109/ICISCE.2017.327>
- Yong, S. P., & Yeong, Y. C. (2018). Human object detection in forest with deep learning based on drone's vision. *2018 4th International Conference on Computer and Information Sciences: Revolutionising Digital Landscape for Sustainable Smart Society, ICCOINS 2018 - Proceedings*. <https://doi.org/10.1109/ICCOINS.2018.8510564>