



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 29.07.2024
Kabul Tarihi : 02.12.2024

Received Date : 29.07.2024
Accepted Date : 02.12.2024

TRAFİK İŞARETLERİNİN TESPİTİNDE FARKLI YOLO MODELLERİNİN KARŞILAŞTIRILMASI

THE COMPARISON OF DIFFERENT YOLO MODELS FOR TRAFFIC SIGN DETECTION

Mehmet Fatih Bekçioğulları^{1*} (ORCID: 0000-0002-0056-9526)

Bünyamin Dikici¹ (ORCID: 0000-0000-0001-6722-5894)

Hakan Açıkgöz² (ORCID: 0000-0002-6432-7243)

Serkan Özbay³ (ORCID: 0000-0001-5973-8243)

¹ Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

² Kahramanmaraş İstiklal Üniversitesi, Yazılım Mühendisliği Bölümü, Kahramanmaraş, Türkiye

³ Gaziantep Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet Fatih BEKÇİOĞULLARI, mehmetfatih.bekciogullari@gibtu.edu.tr

ÖZET

Trafik işaretleri, karayolunda seyahat eden sürücülere yol kısıtlamaları açısından uyarıda bulunmak amacıyla karayollarına yerleştirilmektedir. Bu işaretlerin doğru bir şekilde algılanması ve trafik işaretinin gerektirdiği kısıtlamaya uyulması, sürüş güvenliği açısından önemlidir. Son yıllarda, derin öğrenme algoritmalarının nesne sınıflandırılmasında ve tespitinde başarılı olduğu birçok çalışma ile gösterilmiştir. Bu çalışmada, derin öğrenme tabanlı “You Only Look Once” (YOLO) algoritmaları trafik işaretleri tespiti açısından karşılaştırılmıştır. İlk olarak 877 görüntüden oluşan dört sınıflı trafik işaretleri veri seti elde edilmiştir. Daha sonra YOLOv5, YOLOv8 ve YOLOv9 algoritmaları trafik işareti tanınması açısından incelenmiştir. Deneysel çalışmalarda, tespit algoritmalarının performanslarını değerlendirmek amacıyla duyarlılık, kesinlik, f1 skor ve mAP performans değerlendirme kriterleri açısından incelenmiştir. Elde edilen deneysel sonuçlara göre YOLOv9’un Duyarlılık metriği %90.8, mAP@0.5 metriği %93.1 ve mAP@0.5:0.95 metriği %77.7 olarak hesaplanmıştır. Bu sonuçlar YOLOv9 algoritmasının en iyi trafik işareti tespit algoritması olduğunu doğrulamaktadır.

Anahtar Kelimeler: Derin öğrenme, yolo, trafik işaret tespiti

ABSTRACT

Traffic signs are placed on highways to warn drivers travelling on the highway in terms of road restrictions. It is important for driving safety that these signs are correctly detected and that the restrictions required by the traffic sign are obeyed. In recent years, many studies have shown that deep learning algorithms are successful in object classification and detection. In this study, deep learning based ‘You Only Look Once’ (YOLO) algorithms are compared in terms of traffic sign detection. Firstly, a four-class traffic sign dataset consisting of 877 images is collected. Then, YOLOv5, YOLOv8 and YOLOv9 algorithms are analyzed in terms of traffic sign recognition. In the experimental studies, in order to evaluate the performance of the detection algorithms, recall, precision, f1 score and mAP performance evaluation criteria are analyzed. According to the experimental results obtained, the Recall metric of YOLOv9 is 90.8%, mAP@0.5 metric is 93.1% , and mAP@0.5:0.95 metric is 77.7%. These results validate that YOLOv9 is the best traffic sign detection algorithm.

Keywords: Deep learning, yolo, traffic sign detection

ToCite: BEKÇİOĞULLARI, M.F., DİKİCİ, B., AÇIKGÖZ H., ÖZBAY S. (2025). TRAFİK İŞARETLERİNİN TESPİTİNDE FARKLI YOLO MODELLERİNİN KARŞILAŞTIRILMASI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 138-150.

GİRİŞ

Gelecekte insan gücünün azalacağı ve birçok işin otomatikleşeceği açıkça görülmektedir. Bunun bir örneği de son yıllarda görüntü işleme teknolojisinin gelişmesiyle beraber, akıllı ulaşım sistemlerinin daha popüler hale gelmesi ile görülmektedir. Bununla birlikte, akıllı ulaşım sistemlerinin bazı avantajları ile beraber dezavantajları da bulunmaktadır (Han vd., 2024). Akıllı sürüş sistemlerinin sürüş güvenliği açısından trafik işaretlerini hatasızca yakın bir şekilde algılaması ve doğru bir şekilde işlemesi gerekmektedir. Ancak trafikte zorlu hava koşulları ve düşük ışık yoğunluğu trafik işareti görüntüsünde bulanıklığa sebep olabilmektedir. Ayrıca, trafik işareti tüm görüntüde küçük bir parçada bulunabilmektedir. Bu gibi nedenlerden dolayı gerçek zamanlı trafik işareti algılamakta zorluklar vardır. Bu işaretlerin göz ardı edilmesi veya algılanamaması ise ne yazık ki ölümcül kazaları beraberinde getirebilmektedir (Chen & Luo, 2024).

ImageNet yarışmasında 2012 yılında Krizhevsky ve arkadaşları tarafından önerilen AlexNet büyük ilgi çekmiştir. Özellikle görüntü sınıflandırma konusunda dikkat çekici bir performans sergilemiştir (Krizhevsky vd., 2012). Bununla birlikte Evrişimli Sinir Ağı (ESA) algoritmasına dayalı nesne tespiti çalışmaları hız kazanmıştır. Yapılan çalışmalarda hesaplama yükünün ağır olduğu ve fazla depolama alanına gereksinim duymakta olduğu gösterilmiştir. Ancak, trafik işareti tanıma sistemlerinin hızlı ve doğru karar vermesi gerekmektedir. Dolayısıyla ESA tabanlı algoritmalar trafik işareti tanıma görevi için uygun değildir (Saxena vd., 2024). YOLO hızlı ve efektif bir nesne tanıma algoritması olması sebebiyle, gerçek zamanlı nesne tespitinde en yaygın kullanılan algoritmadır. Nesne tespiti için sınırlayıcı kutular kullanan bu algoritma nesneyi sınıflandırma olasılığı ile tahmin eder. Hesaplama yükünün azlığı ve depolama alanı gereksiniminin ESA algoritması kadar fazla olmaması sebebiyle trafik işareti tespitinde kullanmak için uygun bir algoritmadır (Saxena vd., 2024).

Son yıllarda literatürde trafik işaretlerinin tespiti amacıyla ESA ve YOLO tabanlı yapılan birçok çalışma bulunmaktadır. Küçük vd. çalışmalarında akıllı otonom araçlar için Daha Hızlı R-ESA tabanlı bir algoritma önermişlerdir (Küçük vd., 2021). Aykılıç vd. çalışmalarında trafik işaretlerini sınıflandırmada transfer öğrenme yöntemi kullanarak ESA tabanlı algoritma önermiştir (Aykılıç vd., 2024). Çetinkaya ve Acarman, çalışmalarında ESA tabanlı bir trafik işareti tespiti yöntemi önermişlerdir. Algoritmanın daha hızlı sonuç vermesi amacıyla istatistiksel yöntemlerden yararlanılarak görüntüde trafik işaretinin olma ihtimalinin düşük olduğu bazı yerler elenmiştir. Açık kaynak veri seti ile yapılan çalışma sonucunda belirtilen algoritmanın trafik işareti tespitinde başarılı olduğu performans metrik sonuçları ile gösterilmiştir (Çetinkaya & Acarman, 2020). Çınarer, çalışmasında farklı YOLOv5 algoritmalarının trafik işaretleri tespitinde performanslarını karşılaştırmıştır. Açık kaynak veri seti kullanmışlardır. Elde edilen deneysel sonuçlar hesaplanan, kesinlik, duyarlılık ve mAP performans kriterleri ile değerlendirilmiştir (Çınarer, 2024). Rani vd. çalışmalarında trafik işareti tespitinde görüntülerin birçok sebebe bağlı olarak bulanık olabileceğini belirtmiştir. Çalışmada amaçladıklarının zorlu çevre koşullarında dahi trafik işaretlerinin doğru bir şekilde tanınması olduğuna dikkat çekmişlerdir. Buna çözüm olarak ise HRU-Net tabanlı derin öğrenme algoritmasını görüntüde bulunan bulanıklığı giderici olarak önermişlerdir (Rani vd., 2024). Trappey ve Shen çalışmalarında iki aşamalı trafik işareti tanıma sistemi önermişlerdir. Birinci aşamasında YOLOv7 algoritması ile yerleştirme ve işlemlerinin yapılması hedeflenmiştir. İkinci aşamada ise siyam sinir ağı tabanlı bir ESA algoritması ile birinci aşamada tespit edilen trafik işaretlerinin sınıflandırılması işlemi yapılmıştır (Trappey & Shen, 2024). Saxena vd. çalışmalarında gerçek zamanlı trafik işareti tespiti için güçlendirilmiş YOLOv4 tabanlı algoritma önermişlerdir. Çapa kutularının hesaplanmasında k-ortalamlar kümeleme tekniği kullanılmıştır. Oluşturulan modelin sağlamlığını göstermek amacıyla elde edilen deneysel sonuçlar YOLOv3 ve YOLOv4 algoritmalar ile karşılaştırılmıştır. Ayrıca çalışmada, elde edilen gece görüntülerini iyileştirmek amacıyla gece aydınlatma modeli kullanıldığı belirtilmiştir (Saxena vd., 2024). Megalingam vd. çalışmalarında trafik işaretlerinin tespitinde R-ESA tabanlı bir algoritma önermişlerdir. Modelin geliştirilmesi amacıyla mimarisinde iyileştirmeler yapılmıştır. Ayrıca, veri setinde çeşitli veri artırma yöntemleri uygulanarak modelin güçlendirilmesi hedeflenmiştir. Önerilen modelin performansı Hızlı R-ESA ve Maske R-ESA algoritmaları ile karşılaştırılmıştır (Megalingam vd., 2023). Han vd. çalışmalarında trafik işaretlerinin tespitinde YOLOv5-s tabanlı EDN-YOLO adlı bir algoritma önermişlerdir. Önerilen bu modelde omurga olarak EfficientVit modülü kullanılmıştır. Bu modül ile ağın karmaşıklığının artırılmadan özellik algılama performansının artırılması hedeflenmiştir. Buna ek olarak, etkili bir ayrıştırılmış algılama başlığı ile sınıflandırma ve regresyon işlemleri yapılmıştır. Ayrıca, optimize edilmiş bir kayıp fonksiyonu ile trafik işaretleri gibi küçük nesnelerin tespitinde etkili bir algoritma tasarlandığı belirtilmiştir (Han vd., 2024). Bu çalışmada, trafik işaretlerinin tespiti için YOLOv9 algoritması önerilmiştir. Eğitim için ayrılan veri setine farklı veri artırma yöntemleri uygulanmıştır. Bununla birlikte algoritmanın genelleme potansiyelinin artırılması hedeflenmiştir. Deneysel çalışmalarda, YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9





algoritmalarının performansları nesne tespiti çalışmalarında sıklıkla kullanılan performans değerlendirme kriterlerine göre karşılaştırılmıştır. Bu çalışmanın geri kalanı veri seti, yöntem, performans değerlendirme ölçütleri, deneysel çalışmalar ve sonuç bölümlerinden oluşmaktadır.

Trafik Işığı

Dur İkazı

Hız Limiti

Yaya Geçidi




Şekil 1. Veri Setine Ait Bazı Örnek Resimler

VERİSETİ

Bu çalışmada yaya geçidi, hız limiti, dur işareti ve trafik ışıkları sınıflarından oluşan dört sınıflı halka açık bir veri seti kullanılmıştır¹. Veri setinde toplam 877 adet görüntü bulunmaktadır. Veri setinin deneysel çalışmalarda kullanılması amacıyla öncelikle eğitim, test ve doğrulama görüntüleri sırasıyla %70, %15, %15 oranında rastgele ayrılmıştır. Daha sonra tüm görüntüler 640x640 olarak yeniden boyutlandırılmıştır. Veri setinin artırılması ve ağır genelleştirme potansiyelinin iyileştirilmesi amacıyla sadece eğitim veri setinde döndürme, ortaya çıkarma (exposure) ve bulanıklaştırma veri artırma yöntemlerine başvurulmuştur. Bu işlemlerin sonucunda eğitim veri seti 1839, test veri seti 132 ve doğrulama (validasyon) veri seti 130 görüntüden oluşmaktadır. Şekil 1’ de veri setine ait bazı örnek resimler verilmiştir.

YÖNTEM


Literatürde; R-ESA ailesi (Girshick vd., 2014) (Ren vd., 2017) gibi bölge bazlı nesne tespiti algoritmalarının yanı sıra YOLO ailesi ve SSD (Liu vd., 2016) gibi tek-atış nesne tespiti algoritmaları mevcuttur. Bu çalışmada YOLO algoritması nesne tespiti çalışması yapılmıştır. 2016 yılında Redmon ve arkadaşları bölge bazlı nesne tespiti algoritmalarından daha farklı ve hızlı çalışan bir model önermişlerdir. “You Only Look Once” (YOLO) (Redmon vd., 2016) ismini verdikleri bu modelde; tek bir evrişimli ağ ile sınırlayıcı kutular ve bu kutuların sınıf olasılıkları tahmin edilmektedir. Bu da modelin çok hızlı sonuç vermesine ve gerçek zamanlı uygulamalarda sıklıkla tercih edilmesine sebep olmaktadır. YOLO algoritmalarının temel çalışma mantığı şu şekilde özetlenebilir: Giriş resmi AxA boyutta ızgaralara ayrılarak, n tane sınırlayıcı kutu oluşturulmaktadır. Burada A ve n birer doğal sayıyı temsil etmektedir. Daha sonra ağ her bir sınırlayıcı kutu için olasılık hesaplamaktadır. Sonrasında bir hiperparametre olarak belirlenen belli bir eşik değerinin üstünde değere sahip olan sınırlayıcı kutular seçilmektedir. Seçilen sınırlayıcı kutular ile nesnenin resim içindeki konumu belirlenmektedir. YOLO’ nun YOLOv1 (Redmon vd., 2016), YOLOv2 (Redmon & Farhadi, 2017), YOLOv3 (Redmon & Farhadi, 2018), YOLOv4 (Bochkovskiy vd., 2020), YOLOR (Redmon vd., 2016), YOLOX (Ge vd., 2021), YOLOv5, YOLOv6 (Li vd., 2022), YOLOv7 (C.-Y. Wang vd., 2023), YOLOv8 ve YOLOv9 (C.-Y. Wang vd., 2024), YOLOv10 (A. Wang vd., 2024) gibi farklı versiyonları bulunmaktadır. YOLOv5 2020 yılında, Glen Jocher tarafından tanıtılmıştır. Bir önceki versiyonuna kıyasla algoritmada temel iki değişiklik bulunmaktadır. Bunlardan ilki, EfficientNet temelli EfficientDet algoritmasının kullanılmasıdır. Bu değişiklik ile amaçlanan şey; yüksek doğruluk oranı elde ederken, hesaplama ve hafıza kullanımı açısından daha verimli bir ağ oluşturmaktır. İkinci önemli değişiklik ise bağlantı kutularını üretmek için geliştirilen bir metot olan dinamik bağlantı kutularının kullanılmasıdır. Bu değişiklik YOLOv5’ in; algılanan nesnelerin boyut ve şekline daha uygun bağlantı kutuları oluşmasına olanak tanımaktadır. Ayrıca bu modelde, standart batch normalizasyon yerine çapraz mini-batch normalizasyon kullanılmıştır. Son olarak, YOLOv4’ de de karşımıza çıkan, bir tür havuzlama katmanı olan mekansal piramit havuzlamada (spatial pyramid pooling) bazı iyileştirmeler yapılarak kullanılmıştır. Bu iyileştirmenin amacı, tespit edilmek istenen küçük nesnelerin daha iyi belirlenebilmesini sağlamaktır. YOLOv5 algoritmasının yapısı Şekil 2’ de gösterilmiştir.



Şekil 2. YOLO-V5 Yapısı

¹ <https://www.kaggle.com/datasets/andrewmvd/road-sign-detection/data>

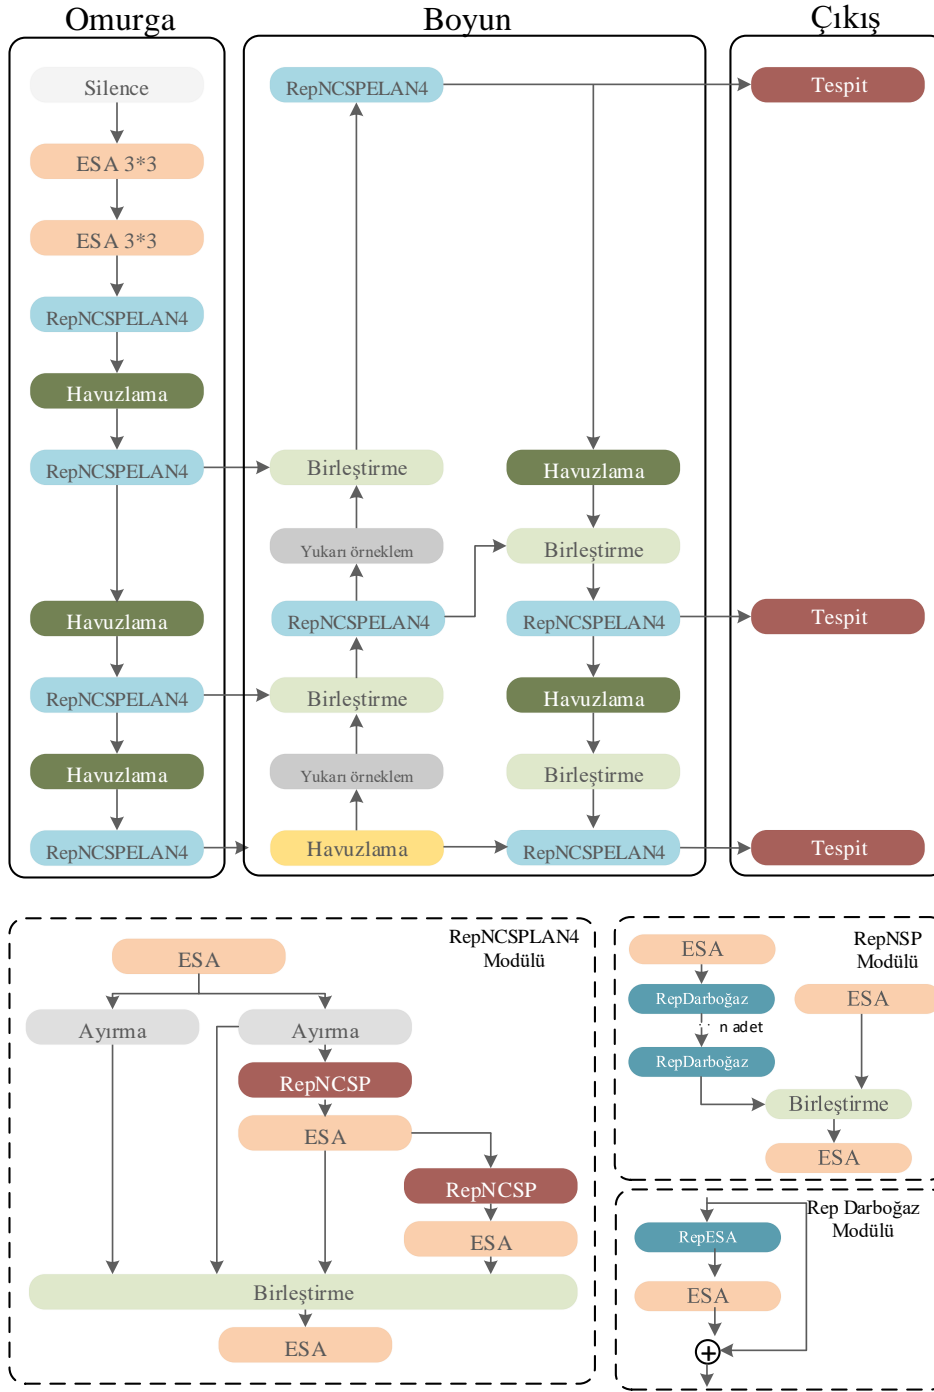
YOLOv8 mimarisi, CSPNet modülü yerine c2f modülünün kullanılması gibi birkaç değişiklik sonucunda YOLOv5 ile aynı mimariyi takip etmektedir (Terven vd., 2023). Ayrıca bu modelde nesnellik, sınıflandırma ve sınırlayıcı kutu tahmin görevlerini bağımsız olarak işlemek için ayrılmış kafalar (decoupled heads) tanıtılmıştır. Nesnellik puanı tahmini için son katman olarak sigmoid katmanı ve sınıflandırma için ise softmax katmanı kullanılmıştır. Öte yandan, sınırlayıcı kutu kaybı için Clou ve DFL kaybı işlevleri kullanılmıştır. Ayrıca sınıflandırma kaybı için ise ikili çapraz entropi kullanılmıştır. Bu kayıplar, özellikle daha küçük nesnelere tespitinde nesne algılama performansını iyileştirmektedir. YOLOv8 algoritmasının yapısı Şekil 3’de sunulmuştur.



Şekil 3. YOLO-V8 Yapısı

Chien-Yao Wang ve diğerleri 2024’te “YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information” başlıklı çalışmaları ile YOLOv9’u tanıtmıştır. Bu makalede tartışılan dört önemli kavram vardır. Bunlar Programlanabilir Gradyan Bilgisi (PGI), Genelleştirilmiş Verimli Katman Toplama Ağı (GELAN), bilgi darboğazı ilkesi ve tersine çevrilebilir işlevlerdir. YOLOv9 nesne algılama, segmentasyon ve sınıflandırma yeteneğine sahiptir (C.-Y. Wang vd., 2024). Bu algoritmanın mimarisi ise Şekil 4’de gösterilmiştir.

Bu çalışmada YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, YOLOv8 ve YOLOv9 algoritmalarından elde edilen performans sonuçları kıyaslanmıştır.



Şekil 4. YOLO-V9 Yapısı

PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

DeneySEL sonuçların değerlendirilmesinde, nesne tespiti çalışmalarında çoğunlukla tercih edilen performans değerlendirme ölçütleri olan Kesinlik (P), Duyarlılık (R), F1-skor ve Ortalama Kesinlik (mAP) metrikleri kullanılmıştır. Kesinlik, tüm pozitif tahminlerden Doğru Pozitifleri (DP) bulma oranıdır. Duyarlılık, DP'lerin gerçek pozitif örneklere oranını ifade etmektedir. F1-skor ise duyarlılık ve kesinlik metriklerinin harmonik ortalamasıdır. Bu performans değerlendirme metrikleri, YOLO algoritmalarının nesne tespiti performansını değerlendirmek için nesnel bir yol göstermektedir (Acikgoz, 2024).

$$Kesinlik = \frac{DP}{DP+YP}$$

(1)

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

$$F1 - skor = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (3)$$

Denklem (1), (2) ve (3)'te sırasıyla kesinlik, duyarlılık ve F1-skor metriklerine ait formüller verilmiştir. Denklem(1) ve (2)'de belirtilen DP, YP ve YN Tablo-1'de verilen hata matrisinde sırasıyla "Doğru Pozitif (DP)", "Yanlış Pozitif (YP)" ve "Yanlış Negatif (YN)" ifade etmektedir. DP doğru tahmin edilen pozitif örnekleri, YP yanlışlıkla pozitif tahmin edilen örnekleri, YN yanlışlıkla negatif tahmin edilen örnekleri ifade etmektedir. Ayrıca gerçekte negatif olan örneklerin negatif olarak tahmin edildiği Doğru Negatif "DN" ile belirtilmiştir.

Tablo 1. Hata Matrisi

	DP	YP
Gerçekteki Sınıf	Doğru Pozitif	Yanlış Pozitif
	YN	DN
	Yanlış Negatif	Doğru Negatif
	Tahmin Edilen Sınıf	

mAP metriği ise nesne tespit algoritmasının davranışı hakkında bilgi içermektedir. AP değeri kesinlik ve duyarlılık parametreleri kullanılarak hesaplanır. Öte yandan bu metrik, birden fazla nesne kategorisinin işlenmesine ve birleşim üzerinden kesişim (IoU) kullanılarak pozitif tahminin tanımlanmasına dayanmaktadır. Bir başka ifadeyle IoU, nesne tespit algoritmasının oluşturduğu örtüşme alanının nesnenin birlik alanına bölünmesi ile elde edilir. Sıfır ile bir arasında değer almaktadır (Terven vd., 2023).

$$AP = \int_0^1 P_r(R_e) dR_e \quad (4)$$

mAP@0.5 metriğinde IoU eşiği 0.5 olarak belirlenmiştir. Bu durumda, IoU 0.5'den büyük hesaplanan değerler için mAP metriği hesaplanmıştır. Bir başka ifadeyle, mAP@0.5 0.5 IoU eşiğinde ortalama hassasiyeti vermektedir. mAP@0.5:0.95 %50'den %95'e kadar farklı IoU eşik değerlerinde ortalama hassasiyet puanlarını göstermektedir.

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_r k \quad (5)$$

Denklem (4) ve (5)'te AP ve mAP formülleri verilmiştir

DENEYSEL ÇALIŞMALAR

Bu çalışmada kullanılan tüm modellerin performans sonuçları Google Colab üzerinden Tesla T4 16 GB ekran kartı, 12 GB RAM ve 80 GB ROM kullanılarak hesaplanmıştır.

Bu çalışmada, YOLO algoritmalarının trafik işaretlerini tespit etmedeki performansını analiz edebilmek adına; YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modellerinden elde edilen performans sonuçları değerlendirilmiştir. Gerçekleştirilen deneysel çalışmalar sonucunda hesaplanan tüm performans metrik sonuçları Tablo 2' de verilmiştir. Kıyaslamalar sonucunda en iyi sonuçların alındığı performans metrikleri koyu renkte belirtilmiştir. Öte yandan, performans metriklerine ait grafikler Şekil 5' de, mAP@0.5 ve mAP@0.5:0.95 metriklerine ait grafikler Şekil 6' da gösterilmiştir.


Tablo 2. Tüm Modellerin Performans Metrik Sonuçlarının Kıyaslanması


Model	Kesinlik	Duyarlılık	F1-Skor	mAP@0.5	mAP@0.5:0.95
YOLOv5-n	0,951	0,832	0,888	0,878	0,685
YOLOv5-s	0,906	0,872	0,889	0,896	0,710
YOLOv5-m	0,948	0,853	0,898	0,876	0,710
YOLOv5-l	0,943	0,857	0,898	0,890	0,712
YOLOv5-x	0,934	0,873	0,902	0,892	0,723
YOLOv8	0,841	0,896	0,868	0,913	0,724
YOLOv9	0,884	0,908	0,896	0,931	0,777

Tablo-2' de verilen mAP metrikleri ile duyarlılık metriği genel olarak incelendiğinde; YOLOv5-n YOLOv5-s, YOLOv5-m, YOLOv5-l ve YOLOv5-x modellerinin en kötü sonuçları verdiği görülmektedir. Bununla beraber ilgili metriklerde, YOLOv8 ve YOLOv9' un tüm YOLOv5 modellerine kıyasla daha yüksek performans sonuçları verdiğini söylemek mümkündür.

Elde edilen sonuçlar kesinlik parametresi yönünden incelendiğinde; YOLOv5 modellerinin genel bir üstünlüğü görülmektedir. En kötü mAP sonuçlarına sahip YOLOv5-n ve YOLOv5-m bu metrikte en iyi sonuçları vermiştir. Duyarlılık parametresi göz önüne alınarak analiz yapıldığında; en iyi sonucun 0.908 ile YOLOv9 modelinde hesaplandığı görülürken en iyi ikinci sonucu ise 0.896 ile YOLOv8 modeli vermiştir. En kötü sonucu ise 0.832 ile YOLOv5-n modelinin verdiği görülmektedir. Duyarlılık metriğinde tüm YOLOv9 ve YOLOv8 modellerinin tüm YOLOv5 modellerine trafik işareti tespitinde açık bir üstünlük kurduğu görülmektedir.

Tablo-2'de yer alan tüm modeller F1-Skor bakımından incelendiğinde; YOLOv5-n YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modelleri için sırasıyla 0.888, 0.889, 0.898, 0.898, 0.902, 0.868 ve 0.896 değerleri elde edilmiştir.

**Şekil 5.** Tüm Modeller İçin Performans Metriklerinin Grafikleri



Şekil 6. Tüm Modeller için mAP@0.5 ve mAP@0.5:0.95 Değerleri

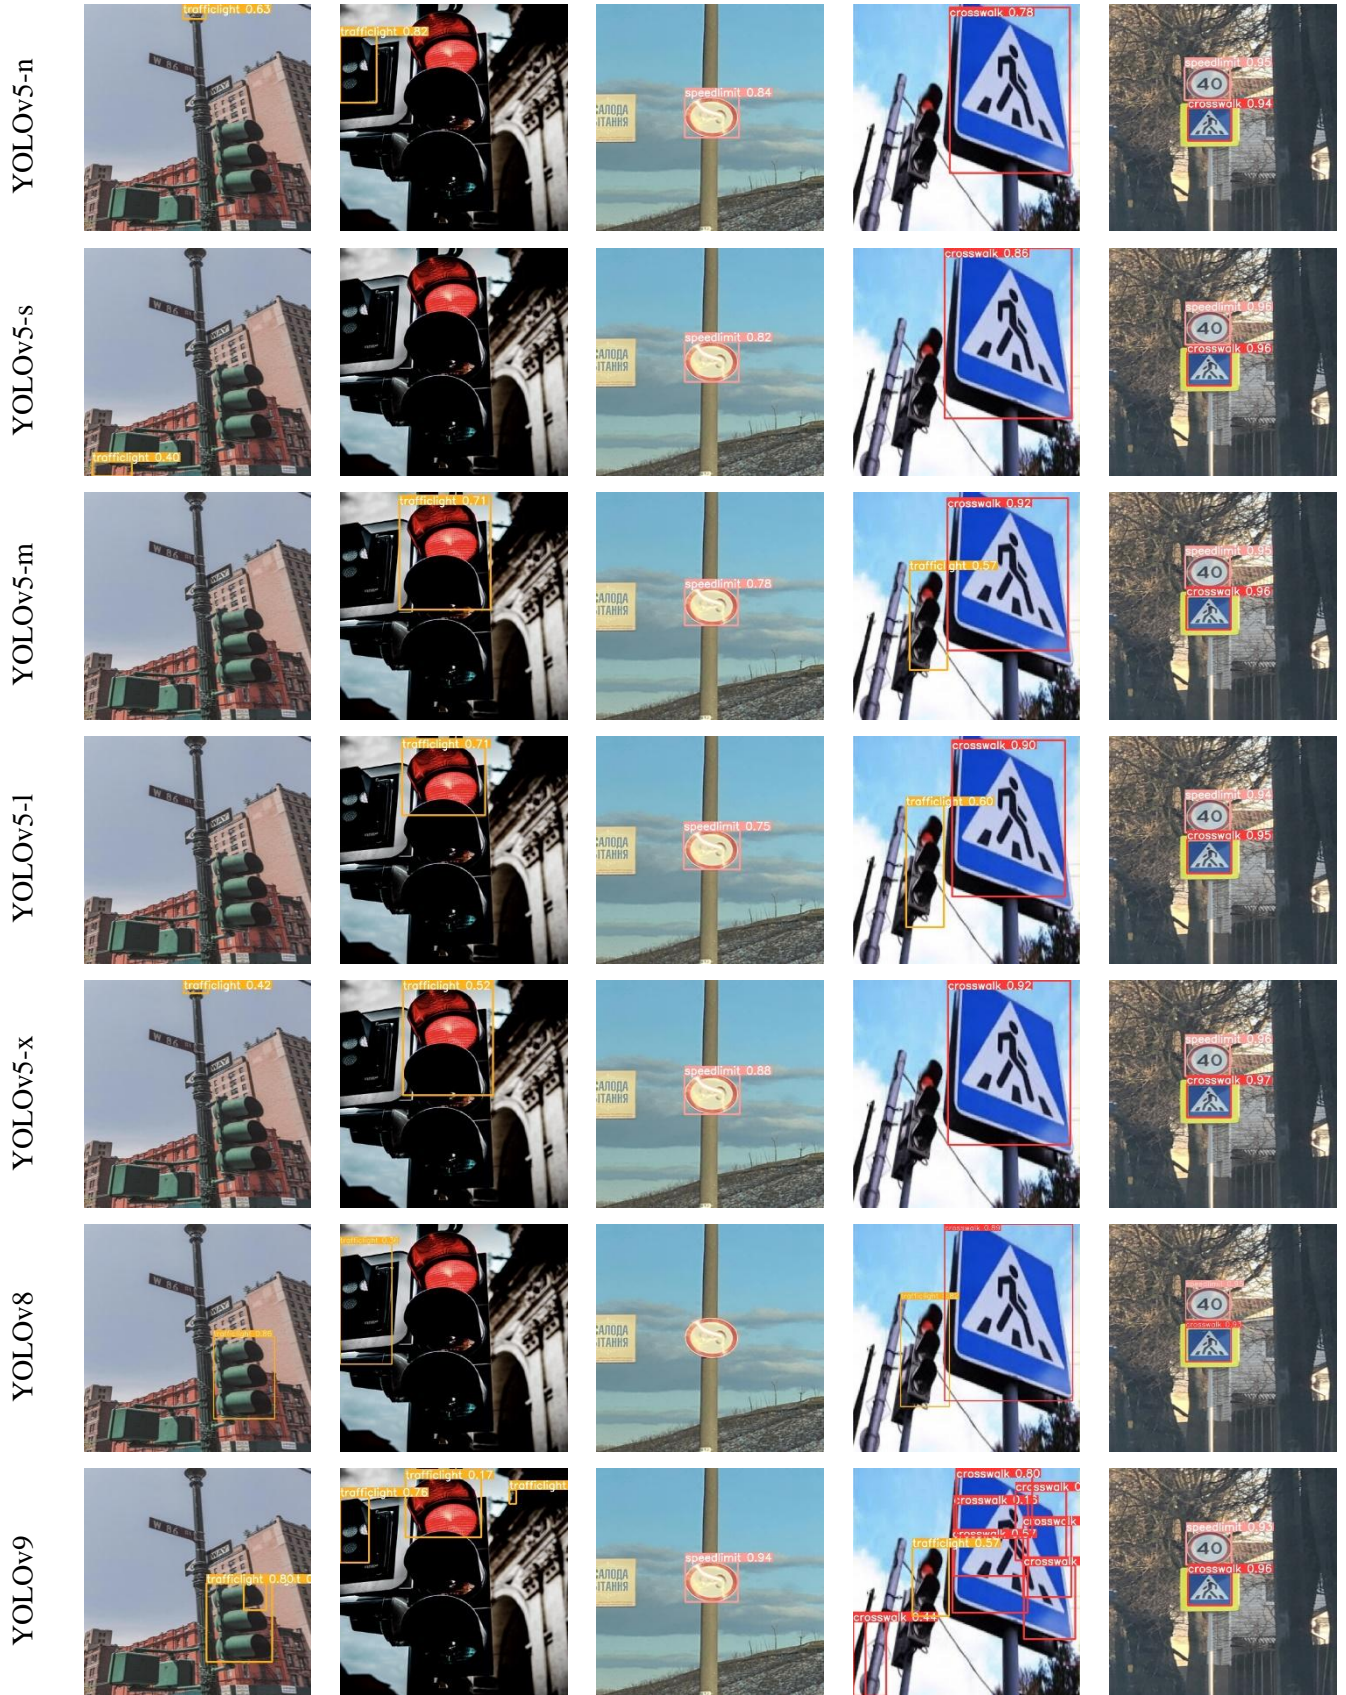
YOLOv8 ve YOLOv9 modelleri, mAP@0.5 metriği ele alındığında sırasıyla 0.913 ve 0.931 ile en iyi sonuçları vermişlerdir. Tüm YOLOv5 algoritmaları arasında 0.896 ile en iyi sonucu veren YOLOv5-s modeli, tüm modeller arasında YOLOv8'in ardından en iyi üçüncü model olmuştur. Buna ek olarak, tüm modeller mAP@0.5:0.95 performans metriği göz önünde bulundurularak değerlendirildiği takdirde 0.777 ile en iyi sonucun YOLOv9' a ait olduğu görülmektedir. En iyi ikinci sonucu veren YOLOv8'in ise bu metrikte hesaplanan değeri 0.724'tür.

Elde edilen deneysel sonuçlar YOLOv9' da kullanılan REPNCSPPLAN4 modülünün trafik işareti tespitinde olumlu bir etki yaparak YOLOv5 ve YOLOv8 ağlarına kıyasla performans sonuçlarını arttırdığını göstermiştir.

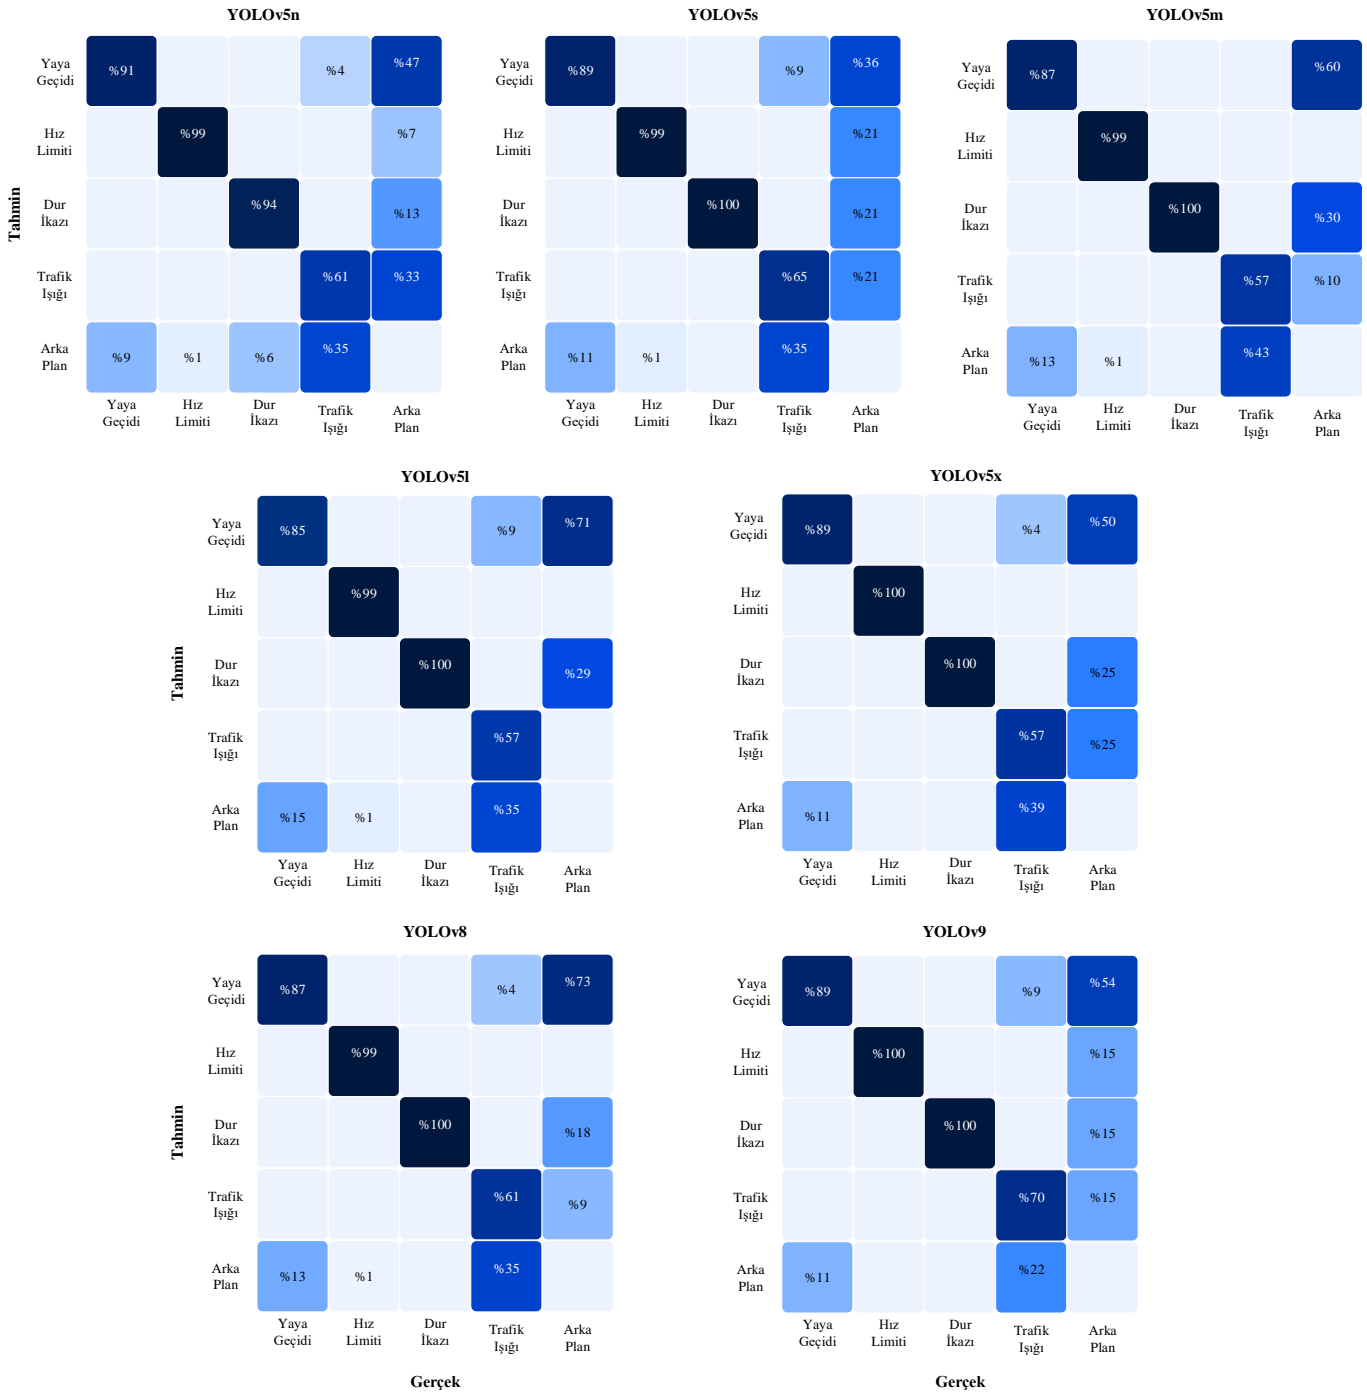
Tablo-2' de yer alan YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modelleri tüm metrikler bakımından değerlendirildiğinde; en iyi sonuçların çoğunlukla YOLOv9 ile en iyi ikinci sonuçların ise genellikle YOLOv8 ile elde edildiği gözlemlenmektedir. Öte yandan, YOLOv5 modellerinin birbirine yakın ve düşük performans sonuçları verdiği görülmektedir. Duyarlılık, mAP@0.5 ve mAP@0.5:0.95 metriklerinde en yüksek performans sonuçlarını veren YOLOv9 için sırasıyla; 0.908, 0.931 ve 0.777 değerleri elde edilmiştir.

Ayrıca Şekil 7'de test görüntülerinden rastgele seçilen beş örneğin, çalışmada kullanılan YOLO algoritmaları tarafından elde edilen çıktıları sunulmuştur. Buna ek olarak, deneysel çalışmada elde edilen YOLO modellerine ait hata matrisleri Şekil 8'de verilmiştir.

Tablo-3'te YOLO modelleri parametreler, katmanlar, floplar, eğitim süreleri ve tahmin süreleri açısından karşılaştırılmıştır. Eğitim süresine göre modeller karşılaştırıldığında en kısa sürede eğitim sürecini tamamlayan modelin yaklaşık bir saat ile YOLOv5-n olduğu görülürken en uzun eğitim süresine sahip olan model yaklaşık altı saat ile YOLOv9 olmuştur. Öte yandan, tahmin süresinin de beklendiği gibi YOLOv5-n'de en kısa olduğu görülmektedir. En uzun tahmin süresi ise 113 milisaniye ile YOLOv9'a aittir. Önerilen YOLOv9 modelinin karşılaştırma modellerine nispeten daha güvenilir ve sağlam olduğu görülmektedir. Önerilen modelin daha gelişmiş GPU'lar ile tahmin süresinin kısaltılabileceği ve akıllı ulaşım sistemlerinde kabul edilebilir seviyeye düşürülebileceği ön görülmektedir.



Şekil 7. Farklı YOLO Algoritmalarından Elde Edilen Test Sonucu Görüntüleri



Şekil 8. Bu Çalışmada Kullanılan Tüm YOLO Modellerine Ait Hata Matrisleri

SONUÇ

Bu çalışmada, trafik işaretlerinin tespitinin gerçekleştirilmesi için YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, YOLOv8 ve YOLOv9 modellerinden elde edilen sonuçlar kıyaslanmıştır. Trafik işaretleri veri seti test, eğitim ve doğrulama olmak üzere üç gruba ayrılmıştır. Adil bir değerlendirme ortamının oluşabilmesi için bu çalışmada yer verilen tüm modeller aynı resimlerle eğitilmiş ve aynı resimlerle test edilmiştir. Öte yandan tüm modeller için batch boyutu 16 olarak seçilirken, dönem sayısı (epoch) 200 olarak belirlenmiştir. Performans değerlendirme sonuçları incelendiğinde YOLOv9 modelinin en iyi duyarlılık, mAP@0.5 ve mAP@0.5:0.95 değerlerini sırasıyla 0.908, 0.931 ve 0.777 olarak verdiği görülmüştür. İlgili metriklere göre en iyi ikinci sonucu ise YOLOv8 modelinin verdiği görülmüştür. YOLOv9 modeli ile YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x ve YOLOv8 modellerinin tespit yeteneğinin önemli ölçüde iyileştirildiği tespit edilmiştir. En iyi ikinci sonucu veren YOLOv8 modelinin mAP@0.5:0.95 metriğinin %7.226 iyileştirildiği hesaplanırken aynı metrikte

YOLOv5-x'in %7.470, YOLOv5-l'nin %9.03, YOLOv5-m'nin %9.334, YOLOv5-s'nin %9.448 ve YOLOv5-n'nin %13.448 iyileştirildiği görülmüştür. Ayrıca önerilen modelin, en iyi ikinci sonucu veren modeli duyarlılık metriğinde %1.354, mAP@0.5 metriğinde ise yaklaşık %2 oranında iyileştirmiştir.

Tablo 3. Bu Çalışmada Kullanılan Tüm YOLO Modellerinin Performans ve Parametre Karşılaştırması

Model	Parametre (M)	Katmanlar	Floplar (G)	Eğitim Süresi (saat)	Tahmin Süresi (ms)
YOLOv5-n	1,769	214	4,2	1,119	5,8
YOLOv5-s	7,030	214	16	1,185	7,1
YOLOv5-m	20,883	291	48,3	1,634	15,9
YOLOv5-l	46,154	368	108,3	2,531	27,9
YOLOv5-x	86,238	445	204,7	3,874	44,8
YOLOv8	11,137	225	28,7	1,783	9,9
YOLOv9	25,440	621	103,2	5,56	113

Elde edilen performans değerlendirme ölçütlerine ve iyileştirme yüzdelerine bakıldığında, YOLOv9 modelinin trafik işaretlerinin tespitinde güvenilir bir model olduğu sonucuna varılmıştır. Bununla birlikte akıllı ulaşım sistemlerinde kullanılması için önemli bir potansiyel taşıdığı değerlendirilmektedir.

KAYNAKLAR

- Acikgoz, H. (2024). An automatic detection model for cracks in photovoltaic cells based on electroluminescence imaging using improved YOLOv7. *Signal, Image and Video Processing*, 18(1), 625-635. <https://doi.org/10.1007/s11760-023-02724-7>
- Aykılıç, Ö., Başarslan, M. S., & Bal, F. (2024). Classification of Traffic Signs Using Transfer Learning Methods. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 24(4), 829-838. <https://doi.org/10.35414/akufemubid.1420978>
- Bochkovskiy, A., Wang, C.-Y., & Liao, H. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. <http://arxiv.org/abs/2004.10934>
- Chen, Y., & Luo, H. (2024). VisioSignNet: A Dual-Interactive Neural Network for enhanced traffic sign detection. *Expert Systems with Applications*, 255. <https://doi.org/10.1016/j.eswa.2024.124688>
- Çetinkaya, M., & Acarman, T. (2020). Trafik İşaret Levhası Tespiti için Derin Öğrenme Yöntemi. *Akıllı Ulaşım Sistemleri Ve Uygulamaları Dergisi*, 3(2), 140-157.
- Çınarer, G. (2024). Deep Learning Based Traffic Sign Recognition Using YOLO Algorithm. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 219-229. <https://doi.org/10.29130/dubited.1214901>
- Ge, Z., Liu, S., Wang, F., Li, Z., & Sun, J. (2021). *YOLOX: Exceeding YOLO Series in 2021*. 1-7. <http://arxiv.org/abs/2107.08430>
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580-587. <https://doi.org/10.1109/CVPR.2014.81>
- Han, Y., Wang, F., Wang, W., Zhang, X., & Li, X. (2024). EDN-YOLO: Multi-scale traffic sign detection method in complex scenes. *Digital Signal Processing: A Review Journal*, 153. <https://doi.org/10.1016/j.dsp.2024.104615>
- Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84 - 90. <https://doi.org/10.1145/3065386>

- Küçük, Ö., Yavşan, E., & Gökçe, B. (2021). Otonom Tabanlı İşaret ve Şerit Tanıma Amacı ile Bir Öğrenme Sisteminin Geliştirilmesi. *International Journal of Engineering Research and Development*, 13(3), 19-25. <https://doi.org/10.29137/umagd.1037237>
- 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*. <http://arxiv.org/abs/2209.02976>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9905 LNCS, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- Megalingam, R. K., Thanigundala, K., Musani, S. R., Nidamanuru, H., & Gadde, L. (2023). Indian traffic sign detection and recognition using deep learning. *International Journal of Transportation Science and Technology*, 12(3), 683-699. <https://doi.org/10.1016/j.ijst.2022.06.002>
- Rani, A. R., Anusha, Y., Cherishama, S. K., & Laxmi, S. V. (2024). Traffic sign detection and recognition using deep learning-based approach with haze removal for autonomous vehicle navigation. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 7. <https://doi.org/10.1016/j.prime.2024.100442>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, faster, stronger. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua*, 6517-6525. <https://doi.org/10.1109/CVPR.2017.690>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*. <http://arxiv.org/abs/1804.02767>
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Saxena, S., Dey, S., Shah, M., & Gupta, S. (2024). Traffic sign detection in unconstrained environment using improved YOLOv4. *Expert Systems with Applications (C. 238)*. Elsevier Ltd. <https://doi.org/10.1016/j.eswa.2023.121836>
- Terven, J., Córdova-Esparza, D. M., & Romero-González, J. A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction (C. 5, Sayı 4, ss. 1680-1716)*. Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/make5040083>
- Trappey, A. J. C., & Shen, O. T. C. (2024). A universal traffic sign detection system using a novel self-training neural network modeling approach. *Advanced Engineering Informatics*, 62. <https://doi.org/10.1016/j.aei.2024.102674>
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). *YOLOv10: Real-Time End-to-End Object Detection*. <http://arxiv.org/abs/2405.14458>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2023). *YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors*. 7464-7475. <https://doi.org/10.1109/cvpr52729.2023.00721>
- Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). *YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information*. <http://arxiv.org/abs/2402.13616>