



Demiryolu Ortamında Nesne Tespiti için Derin Öğrenme Yöntemlerinin Geliştirilmesi ve Zed Kamerası ile Mesafe Ölçümü

Muhammed Amir ELMUHAMMEDCEBBEN¹ , İlhan AYDIN¹ , Mehmet SEVİ^{*2}

¹ Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elâzığ, Türkiye

² Muş Alparslan Üniversitesi, Bilgi İşlem Daire Başkanlığı, Muş, Türkiye

*m.sevi@alparslan.edu.tr

(Alınış/Received: 09.03.2025, Kabul/Accepted: 11.04.2025, Yayımlama/Published: 31.07.2025)

Öz: Demiryolu güvenliğinin sağlanması, dinamik ortamlarda doğru ve gerçek zamanlı nesne tespiti gerektiren kritik bir mühendislik problemidir. Bu çalışmada, demiryolu izleme süreçlerini iyileştirmek amacıyla derin öğrenme tabanlı nesne tespiti modelleri geliştirilmiş ve RailSem19 veri seti kullanılarak YOLOv8, YOLOv9, YOLOv11 ve Faster R-CNN modelleri eğitilerek entegre edilmiştir. Ayrıca, nesnelerin mesafe ölçümlerinin hassasiyetini artırmak için ZED stereo kamerası kullanılmıştır. DeneySEL bulgular, YOLOv9 modelinin doğruluk ve işlem verimliliği açısından en iyi dengeyi sağladığını ortaya koymakta olup, bu modelin ortalama doğruluk (mAP50) değeri %52,14 olarak hesaplanmış ve çıkarım süresi optimize edilmiştir. Önerilen yöntem, otonom demiryolu sistemleri ve güvenlik izleme uygulamaları için önemli bir potansiyel taşımaktadır. Gelecekteki çalışmalar, veri artırma teknikleri, yapay zekâ destekli yorumlanabilirlik ve çoklu sensör füzyonu ile modelin dayanıklılığını artırmaya odaklanacaktır.

Anahtar kelimeler: Derin öğrenme, Demiryolu güvenliği, Nesne algılama, Mesafe ölçümü, RailSem19, ZED kamera

Developing Deep Learning Methods for Object Detection and Using Zed Camera for Distance Measurement in Railway Environment

Abstract: Ensuring railway safety is a critical engineering problem that requires accurate and real-time object detection in dynamic environments. In this study, deep learning-based object detection models are developed to improve railway monitoring processes, and YOLOv8, YOLOv9, YOLOv11, and Faster R-CNN models are trained and integrated using RailSem19 dataset. In addition, a ZED stereo camera is used to increase the precision of distance measurements of objects. Experimental findings reveal that the YOLOv9 model provides the best balance in terms of accuracy and computational efficiency, the average accuracy (mAP50) value of this model is calculated as 52.14% and the inference time is optimized. The proposed method has significant potential for autonomous railway systems and safety monitoring applications. Future studies will focus on improving the robustness of the model with data augmentation techniques, artificial intelligence-supported interpretability, and multi-sensor fusion.

Keywords: Deep learning, Railway safety, Object detection, Distance measurement, RailSem19, ZED camera

1. Giriş

Demiryolu taşımacılığı sistemleri, yolcu ve yük taşımacılığının verimli bir şekilde gerçekleştirilmesini sağlayarak küresel ulaşım ve lojistik ağlarının temel unsurlarından biridir. Bununla birlikte, demiryolu güvenliğinin ve operasyonel verimliliğin sağlanması, özellikle raylar üzerinde ve çevresinde potansiyel engellerin tespit edilmesi ve giderilmesi açısından sürekli bir zorluk teşkil etmektedir. Bu tür aksaklıkların yol açabileceği sonuçlar; gecikmeler ve finansal kayıplardan, ciddi kazalara kadar geniş bir yelpazede değişiklik gösterebilir. Bu nedenle, nesne tespitinin doğruluğunu artırmak, mesafe ölçümünü geliştirmek ve gerçek zamanlı tepki

Atıf için/Cite as: M. A. Elmuhammedcebben, İ. Aydın, M. Sevi, "Demiryolu ortamında nesne tespiti için derin öğrenme yöntemlerinin geliştirilmesi ve zed kamerası ile mesafe ölçümü," *Demiryolu Mühendisliği*, sy. 22, ss. 10-24, Temmuz 2025. doi: 10.47072/demiryolu.1645019

mekanizmaları oluşturmak, demiryolu güvenliğini artırmada kritik öneme sahiptir. Otomatik izleme sistemlerinde kaydedilen ilerlemelere rağmen, mevcut yöntemler, özellikle elverişsiz hava koşulları ve değişken ışık senaryoları altında dinamik ve öngörülemeyen ortamlarda yetersiz kalabilmektedir.

Demiryolu operasyonlarının sürekliliğini ve güvenliğini sağlamak, tehlikeleri gerçek zamanlı olarak belirleyip müdahale edebilen sağlam nesne tespit sistemlerini gerektirmektedir. Güvenilir engel tespiti, yalnızca çarpışmaların ve raydan çıkmaların önlenmesine katkıda bulunmakla kalmaz, aynı zamanda otomatik tren kontrol sistemlerine destek sağlayarak tespit edilen nesnelerin niteliğine ve konumuna göre proaktif önlemler alınmasını mümkün kılar. Buna ek olarak, nesne tespiti ile mesafe ölçüm teknolojisinin entegrasyonu, durumsal farkındalığı artırarak tren kontrolü ve altyapı bakımında zamanında karar alınmasını sağlar.

Son yıllarda derin öğrenme alanında kaydedilen ilerlemeler, demiryolu güvenliği uygulamalarında nesne tespit yeteneklerini önemli ölçüde geliştirmiştir. YOLO (You Only Look Once) [1], Faster R-CNN [2], Mask R-CNN [3, 4] ve SSD (Single Shot Multibox Detector) [4] gibi en güncel algoritmalar, geleneksel görüntü işleme tekniklerine kıyasla önemli iyileştirmeler sunmaktadır. Bu modeller, ortalama doğruluk (mAP) değerlerinde %88'e ve saniyede 48 kareye (FPS) kadar çıkabilen başarımlar sergilemiştir [5]. Modellerin etkinliği, uygulama alanına göre farklılık göstermektedir: YOLO, gerçek zamanlı performansta üstünlük sağlarken [6,7], Faster R-CNN, kısmen gizlenmiş veya küçük nesnelerin belirlenmesinde etkili olduğunu kanıtlamış, ancak hesaplama karmaşıklığı nedeniyle gerçek zamanlı işlem gücü açısından bazı sınırlamalar göstermiştir; Mask R-CNN ve U-Net ise yüksek doğrulukta segmentasyon gerçekleştirebilmektedir, U-Net'in demiryolu raylarının segmentasyonunda %91,8'lik bir ortalama kesişim oranı (mIoU) başarısı elde ettiği ve önceki modellere kıyasla önemli bir gelişme sağladığı rapor edilmiştir [8]. Ayrıca, SE dikkat birimleri, optimize edilmiş çapa kutuları ve iyileştirilmiş sınır regresyon kayıp fonksiyonları gibi ek geliştirmeler, özellikle küçük nesnelerin tespitinde bu modellerin doğruluğunu daha da artırmıştır [8].

Standart nesne tespitinin ötesinde, LiDAR (Light Detection and Ranging), termal görüntüleme ve derin öğrenme algoritmalarını bir araya getiren çok modlu yaklaşımlar, özellikle düşük ışık koşulları ve olumsuz hava şartlarında tespit performansını artırmıştır [9]. RFID (Radio Frequency Identification) [10], monoküler görüntüleme ve stereo kameralar (ZED kameralar [11]) gibi mesafe ölçüm teknolojileri, gerçek zamanlı mekânsal farkındalık ve çarpışma önleme mekanizmaları sunma potansiyeliyle araştırılmaktadır. Ancak, bu yöntemler genellikle yüksek hızlı demiryolu ortamlarında gerekli mekânsal hassasiyeti sağlayamamaktadır ve bu durum, ek iyileştirmelere duyulan ihtiyacı ortaya koymaktadır. Buna ek olarak, veri artırma stratejileriyle birleştirilen dönüşüm tabanlı öğrenme tekniklerinin tespit doğruluğunu önemli ölçüde artırdığı gösterilmiştir. Örneğin, Inception-ResNet-v2 ve dengeli sınıf artırma tekniklerinden yararlanan modellerin %94,06'ya varan tespit doğruluğu sağladığı, yüksek kesinlik ve geri çağırma oranlarına ulaştığı tespit edilmiştir [12]. Öte yandan, Generative Adversarial Networks (GANs) gibi üretken ağlar, veri kıtlığı sorununu gidermek amacıyla kullanılmış olup, pix2pix gibi çerçevelerle verilerin genişletilmesi ve yüksek hızlı demiryolu senaryolarında gerçek zamanlı nesne tespitinin iyileştirilmesi sağlanmıştır [13].

Bu gelişmelere rağmen, demiryolu güvenliğine yönelik nesne tespiti ve mesafe ölçümünün pratik uygulamalarında önemli eksiklikler devam etmektedir. Mevcut modeller, sınırlı veri seti çeşitliliği, demiryolu özelinde yetersiz eğitim ve derinlik algılama mekanizmalarıyla entegrasyon eksikliği nedeniyle çevresel zorluklarla mücadelede zorlanmaktadır [14,15,16]. Mevcut çalışmalar, genellikle tespit doğruluğuna odaklanırken, nesne tespiti ile stereo görüş, LiDAR veya radar gibi tamamlayıcı teknolojilerin entegrasyonunu ihmal etmektedir. Oysa, hassas mesafe ölçümü ve gerçek zamanlı karar alma süreçleri için bu teknolojilerin birlikte kullanımı kritik öneme sahiptir. Ayrıca, YOLOv8 ve Faster R-CNN gibi derin öğrenme tabanlı nesne tespiti

modelleri ile ZED kameraları gibi stereoskopik kameraların eşzamanlı kullanımı hala yeterince incelenmemiştir [17]. Bu durum, bu teknolojilerin etkili bir şekilde nasıl birleştirilebileceğine dair bilgi eksikliğini ortaya koymaktadır.

RailSem19 [18] gibi demiryolu özelindeki veri setlerinin sınırlı olması, model genellemesinin farklı operasyonel koşullara yayılmasını zorlaştırmaktadır. Ayrıca, sınıf dengesizliği, olumsuz hava koşullarına duyarlılık ve hesaplama kısıtlamaları, bu sistemlerin gerçek zamanlı uygulamalara entegrasyonunu engellemektedir. Bunun yanı sıra, nesne tespiti ve mesafe ölçümünü entegre eden, aynı zamanda sensör konumlandırmasını optimize eden kapsamlı çerçevelerin eksikliği de dikkat çekmektedir. Gelecekteki araştırmalar, mevcut gelişmeleri değerlendirirken tamamlayıcı teknolojileri bütünleştirerek bu sınırlamaları ele alan sağlam ve ölçeklenebilir çözümler geliştirmeye odaklanmalıdır.

Bu çalışma, YOLOv8 ve YOLOv11 gibi modern derin öğrenme modellerini ZED kameralar aracılığıyla stereoskopik görüş teknolojisi ile entegre eden iki bileşenli bir sistem geliştirmeyi ve değerlendirmeyi amaçlamaktadır. Temel hedefler, bu modellerin RailSem19 veri seti üzerindeki doğruluk, hız ve güvenilirliğini değerlendirmek ve zorlu demiryolu senaryolarında etkinliklerini analiz etmektir. Ayrıca, nesne tespiti ile mesafe ölçümünün birleştirilmesi, durumsal farkındalığı artırarak gerçek zamanlı karar alma süreçlerini iyileştirmeyi amaçlamaktadır. Önerilen sistemin performansı, olumsuz hava koşulları ve değişken ışık ortamları dâhil olmak üzere çeşitli çevresel koşullar altında değerlendirilecek ve güvenilir gerçek zamanlı çalışmayı sağlayacak şekilde optimize edilecektir.

Gelişmiş derin öğrenme algoritmalarının stereoskopik görüntüleme teknolojisi ile entegrasyonu, demiryolu güvenliğini artırmada umut vadeden bir yaklaşımdır. Bu yöntem, gerçek zamanlı engel tespiti ve hassas mesafe tahmini yoluyla proaktif risk azaltımına olanak tanımaktadır. Bu araştırmanın bulguları, farklı ve zorlu koşullarda çalışabilen akıllı demiryolu sistemlerinin geliştirilmesine katkı sağlayarak, dünya genelinde daha güvenli ve verimli demiryolu ağlarının oluşturulmasına yardımcı olacaktır.

2. Metot

Bu bölüm, önerilen derin öğrenme tabanlı nesne tespiti ve mesafe ölçüm çerçevesi için ayrıntılı ve tekrarlanabilir bir metodoloji sunmaktadır. Bu yaklaşım, gerçek dünya demiryolu koşullarında doğru engel tespiti ve mesafe tahmini sağlamak için ZED kamerası kullanarak stereoskopik vizyon ile gelişmiş nesne tespiti modellerini entegre etmektedir.

2.1. Veri kümesine genel bakış

Bu çalışmada, nesne tespiti modellerini eğitmek ve değerlendirmek için RailSem19 veri kümesi kullanılmıştır. Bu veri kümesi, demiryolu sahnelerinin anlaşılması için özel olarak tasarlanmış ve halka açık olarak erişime sunulmuş bir veri kümesidir. RailSem19, çeşitli hava koşulları, farklı aydınlatma ve coğrafi ortamlar altında çekilmiş 8.500 görüntü içermektedir. Demiryolu hatları, insanlar, sinyaller ve araçlar dahil olmak üzere 19 farklı nesne kategorisini barındıran bu veri kümesi, demiryolu ortamlarında nesne tespiti görevleri için kapsamlı bir karşılaştırma ölçütü sunmaktadır.

Veri kümesi, demiryolu güvenliği için kritik unsurlara odaklanarak geniş bir nesne kategorisi yelpazesi sunmaktadır; bu unsurlar arasında insanlar ve demiryolu hatları öne çıkmaktadır. Tespit performansını artırmak amacıyla, Çalışmada beş temel kategoriye odaklanılmıştır: demiryolu hatları (demiryolu ortamının ana kategorisi), insanlar (demiryolu güvenliği açısından önemli bir kategori), engeller (demiryolu tehlikelerinin tespiti için temel bir kategori), sinyaller ve araçlar (her iki kategori de demiryolu hatları çevresindeki çevresel algılama ve güvenliğe katkı

sağlamaktadır). Bu kategorilerin seçimi, gerçek zamanlı olarak tehlikelerin önlenmesi amacıyla belirlenmiş olan ana hedefle uyumludur. Şekil 1’de veri setinden örnek görüntüler görülmektedir.



Şekil 1. Veri setinden örnek demiryolu hattı görüntüleri

RailSem19, farklı aydınlatma koşulları (gündüz, gece, sis ve bulutlar) altında çekilmiş görüntüler içermektedir, bu da modelin güçlü bir genelleme yeteneği kazanmasını sağlamaktadır. Ayrıca, veri kümesi coğrafi çeşitliliğe sahiptir hem de kentsel hem de kırsal demiryolu ortamlarını kapsayarak, modelin farklı operasyonel senaryolara uyum sağlama yeteneğini artırmaktadır.

2.2. Ön işleme

Ön işleme, derin öğrenme modelleri için veri kümesinin geliştirilmesinde önemli bir rol oynamaktadır. Aşağıdaki ön işleme teknikleri uygulanmıştır:


Modelin genelleme yeteneğini artırmak amacıyla çeşitli veri artırma teknikleri kullanılmıştır. Bu teknikler şunlardır:

- Yatay çevirme: İki yönlü demiryolu senaryolarını hesaba katmak amacıyla uygulanmıştır.
- Dönme ve ölçekleme: Perspektif değişimlerinden kaynaklanan varyasyonları oluşturmak için kullanılmıştır.
- Kontrast ayarlaması: Farklı aydınlatma koşullarını simüle ederek modelin bu koşullara karşı dayanıklılığını artırmayı hedeflemiştir.
- Gauss gürültüsü ekleme: Sensör kaynaklı gürültülere karşı modelin sağlamlığını artırmak amacıyla uygulanmıştır.

Bu veri artırma teknikleri, gerçek dünya senaryolarındaki çeşitliliği yansıtarak veri kümesinin etkin boyutunu artırmakta ve modelin daha geniş koşullarda başarılı bir şekilde çalışmasına katkı sağlamaktadır.

Tüm görüntüler, YOLO tabanlı modeller için standart giriş boyutu olan 640×640 piksele yeniden boyutlandırılmıştır. Bu, hesaplama verimliliğini sağlarken, temel özellik detaylarının korunmasını temin etmektedir.

RailSem19 veri setindeki anotasyonlar başlangıçta poligon maskeleri biçiminde sağlanmıştır. Bu anotasyonlar, nesne tespiti için kullanılan YOLO formatına dönüştürülerek sınırlayıcı kutu koordinatları elde edilmiş ve Faster R-CNN modeliyle eğitim yapılabilmesi amacıyla COCO formatına çevrilmiştir. Gerçekleştirilen bu dönüşüm, özel olarak geliştirilen tespit mimarilerimizle sorunsuz bir entegrasyon sağlanmasını kolaylaştırmıştır. Şekil 2’te, ön işleme sürecinde gerçekleştirilen adımların sırasını ve ilişkilerini görsel olarak sunan açıklayıcı bir akış diyagramı yer almaktadır.




Şekil 2. Ön işleme akış diyagramı

2.3. Model mimarisi

Bu çalışmada, nesne tespiti için dört ileri düzey derin öğrenme modeli kullanılmıştır: YOLOv8, YOLOv9, YOLOv11 ve Faster R-CNN. Her bir model, nesne tespiti görevlerinde sahip olduğu benzersiz güçlü yönleri nedeniyle seçilmiştir.

YOLOv8, gerçek zamanlı performans ve yüksek doğruluğun birleşimiyle tanınan, son teknoloji bir tek aşamalı dedektördür. YOLO serisinin önceki yinelemeleri üzerine inşa edilen YOLOv8 hem tespit hızı hem de doğruluğunu artıran birkaç yenilikçi özellik entegre etmektedir. Bu model, verimli özellik çıkarımı için CSPDarknet53 sırt kısmını kullanmakta ve önceden tanımlanmış

referans kutularına gerek duymadan referanssız tespit yöntemini tanıtarak, tespit verimliliğini artırmaktadır. YOLOv8 mimarisi Şekil 3'te görülmektedir.



Şekil 3. YOLOv8 mimarisi [19]

YOLOv8'in ana özelliklerinden biri, çok ölçekli özellik füzyonunu kolaylaştıran Path Aggregation Network (PAN) olup, gelişmiş bir kayıp fonksiyonu da sınıflandırma ve lokalizasyon hatalarını birleştirerek model performansını daha da optimize etmektedir. Model, yüksek kare hızına sahip çıkarımlar için tasarlanmış olup, bu özellik onu gerçek zamanlı uygulamalar için uygun hale getirmektedir.

YOLOv9, YOLOv8 mimarisinin bir evrimini temsil etmekte olup, özellik çıkarımı, model verimliliği ve karmaşık tespit görevlerine uyum sağlama konularında önemli iyileştirmeler sunmaktadır. Dikkate değer yenilikler arasında, çeşitli ölçeklerdeki nesnelerin tespitini optimize eden dinamik referans atama ve çok ölçekli özellik işleme yeteneğini geliştiren ileri düzey bir uzamsal piramit kümelenme yaklaşımı bulunmaktadır. Ayrıca, YOLOv9, modelin ilgili özelliklere odaklanmasını ince ayar yaparak performansı artıran dönüştürücü tabanlı dikkat mekanizmalarını da içermektedir, bu da zorlu ortamlarda daha iyi sonuçlar elde edilmesini sağlamaktadır.


YOLOv9'un ana güçlü yönlerinden biri, küçük nesnelerin tespiti konusundaki başarısıdır; bu özellik, genellikle küçük ve yüksek hassasiyet gerektiren nesnelerin bulunduğu demiryolu ortamları için özellikle uygundur. Model, aynı zamanda küçük nesnelerin daha iyi işlenebilmesi için uyarlanabilir özellik örnekleme sunmakta olup, düşük hesaplama karmaşıklığını koruyarak, özellikle uç cihazlarda verimli performans sağlar. Diğer iyileştirmeler arasında, hızdan ödün vermeden doğruluğu artıran, optimize edilmiş son işlem teknikleri (non-maximum suppression-NMS) bulunmaktadır.

YOLOv11, YOLO serisinin en son evrimidir ve tespit doğruluğu ile hesaplama verimliliğinde önemli iyileştirmeler sunmaktadır. Model, özelliklerin dinamik olarak farklı nesne ölçeklerine uyum sağlamasını sağlayan bir Mixture of Experts (MoE) sırt kısmına sahiptir, bu da genelleme yeteneğini artırmaktadır [20]. Adaptive Spatial Feature Fusion (ASFF) ise çok ölçekli agregasyonu daha da geliştirerek yanlış pozitifleri azaltmakta ve tespit hassasiyetini artırmaktadır [21].

Model, özellikle veri kısıtlamalarının olduğu demiryolu ortamlarında faydalı olan kontrastif öğrenme ile kendiliğinden denetimli ön eğitim kullanmaktadır. Ayrıca, dönüşüm tabanlı hafif dikkat mekanizması, karmaşık senaryolarda daha yüksek doğruluk için özellik seçimlerini optimize etmektedir. YOLOv11, kanal düzeyi ve uzamsal dikkat birleştiren hibrit bir dikkat modülü de entegre ederek, zorlu ortamlarda geliştirilmiş performans için özellik temsilini ince ayar yapmaktadır.

Dinamik bir sinirsel mimari arama (NAS) çerçevesi, RailSem19 gibi görevler için sırt kısmı ve tespit başlığının optimizasyonunu otomatikleştirmektedir. Semantik segmentasyon ve derinlik tahmini gibi görevlerle çoklu görev öğrenmesinin dahil edilmesi, özellik alanını zenginleştirir ve genelleme yeteneğini artırır. Modifiye edilmiş bir CSPNeXt sırt kısmı ve verimli referanssız tespit başlığı ile donatılan YOLOv11, RailSem19 üzerinde %55,2'lik bir ortalama mAP elde ederek YOLOv8 ve YOLOv9'u geride bırakmaktadır. NVIDIA Jetson Xavier gibi uç cihazlar için tasarlanmış optimize edilmiş çıkarım motoru, düşük gecikme süresi ve bellek kullanımı ile gerçek zamanlı performans sağlar.

Faster R-CNN, özellikle karmaşık ve yoğun nesne tespiti senaryolarında yüksek doğruluğu ile tanınan iki aşamalı bir nesne tespiti modelidir. Birinci aşamada, aday bölgeler oluşturmak için Region Proposal Network (RPN) kullanılır; ikinci aşamada ise sınıflandırma ve sınırlayıcı kutu regresyonu için Fast R-CNN modülü devreye girer. Çıkarım hızı YOLO tabanlı modellere göre daha yavaş olsa da yoğun veya üst üste binen nesnelerin tespitinde doğruluğu ile öne çıkar. Fast R-CNN mimarisi Şekil 4'te görülmektedir.



Şekil 4. Faster R-CNN mimarisi [22]

Model, derin özellik çıkarımı için ResNet-101 sırt kısmını kullanmakta ve sabit boyutlu özellik haritaları üretmek için Region of Interest (RoI) havuzlama yöntemini uygulamaktadır, bu da performansını optimize etmektedir. Daha yavaş çıkarım hızına rağmen, Faster R-CNN'in doğruluğu, hızdan ziyade doğruluğun ön planda olduğu uygulamalar için ideal hale getirmektedir.

2.4. ZED kamerası ve mesafe ölçümü

ZED stereo kamerası, demiryolu ortamındaki tespit edilen nesnelere olan mesafeyi ölçmek için sisteme entegre edilmiştir. Kamera, sol ve sağ görüntü çiftleri arasındaki farkları hesaplayarak derinlik haritaları oluşturmak için stereoskopik bir vizyon sistemi kullanmaktadır. Nesne tespiti ve stereo derinlik tahmini entegrasyonu, gerçek zamanlı mesafe ölçümü yapılmasını sağlayarak demiryolu güvenliği uygulamalarını güçlendirmektedir. Çalışmada kullanılan ZED kamera Şekil 5'te görülmektedir.



Şekil 5. ZED 2 kamera

Mesafe ölçüm süreci, derinlik haritası hesaplamasıyla başlar; burada, fark değeri ZED SDK kullanılarak gerçek dünya derinlik değerlerine dönüştürülür. Nesne tespiti modellerinden (YOLO veya Faster R-CNN) elde edilen sınırlayıcı kutu koordinatları daha sonra derinlik haritasına yerleştirilir. Her bir nesnenin merkez noktasındaki Z-derinlik değeri çıkarılır ve mesafe ölçümü sağlanır.

Mesafe D hesaplaması Denklem 1'de görülmektedir.

$$D = \frac{f \cdot B}{d} \quad (1)$$

Burada f odak uzaklığı, B kameralar arasındaki temel mesafe ve d ise farktır. Post-processing işlemleri, örneğin medyan filtreleme, uç verilerin kaldırılması ve derinlik tahminlerinin iyileştirilmesi amacıyla uygulanır, böylece doğru mesafe ölçümleri sağlanır.

Sistemin senkronizasyonu, gerçek zamanlı işlemeyi garanti ederek, nesne tespiti çıktısını (sınırlayıcı kutular ve sınıf etiketleri) derinlik bilgisiyle birleştirir ve nesnenin türü, konumu ve mesafesini içeren kapsamlı bir sonuç elde edilmesini sağlar.

2.5. Eğitim hazırlığı

Bu bölüm, bu çalışmada kullanılan nesne tespiti modellerinin eğitim prosedürlerini ve ZED kamerası kullanarak mesafe ölçümü için uygulanan araçlar ve metodolojileri açıklamaktadır. Eğitim kurulumu, aydınlatma, hava koşulları ve coğrafi şartlardaki varyasyonları göz önünde bulundurarak, demiryolu ortamlarında doğruluk ve dayanıklılığı optimize etmek için titizlikle tasarlanmıştır.

Nesne tespiti modelleri (YOLOv8, YOLOv9, YOLOv11 ve Faster R-CNN), RailSem19 veri kümesi üzerinde, hiper parametre optimizasyonu ve veri kümesine özgü değişiklikler içeren

yapılandırılmış bir işlem süreci kullanılarak eğitilmiştir. Eğitim süreci, aşağıdaki temel unsurları içermektedir:

- Giriş Görüntü Boyutu: Tüm modeller için 640×640 piksel.
- Öğrenme Hızı: 0.001, sinüzoidal soğuma planlamasıyla.
- Batch Boyutu: Tüm modeller için 16.
- Optimizatör: YOLO modelleri için Adam optimizatörü; Faster R-CNN için ise yakınsama iyileştirmek amacıyla momentumlu Stokastik Gradyan İnişi (SGD).
- Döngü Sayısı: YOLOv8 ve YOLOv11 için 50; YOLOv9 ve Faster R-CNN için 25 (hesaplama verimliliği göz önünde bulundurularak).
- Kayıp Fonksiyonu: Sınıflandırma için çapraz entropi; sınırlayıcı kutu regresyonu için tam kesişim üzerinden birlikte (CIoU).
- Veri Artırma: Genelleme ve dayanıklılığı artırmak amacıyla rastgele kırpma, döndürme, ölçekleme ve renk bozulması uygulanmıştır.
- Eğitim-Doğrulama Bölünmesi: Eğitim için %70, doğrulama için %20 ve test için %10; parametre ayarı ve model değerlendirmesi için yeterli veri sağlanmıştır.

2.6. Değerlendirme ölçütleri

Değerlendirme ölçütleri, nesne tespiti modellerinin ve entegre edilmiş mesafe ölçüm sisteminin performansını ve güvenilirliğini değerlendirmek için kritik öneme sahiptir. Nesne tespiti modellerimizin performansını değerlendirmek için standart değerlendirme ölçütleri kullanılmıştır.

- mAP@50 (IoU=0.5'te Ortalama Doğruluk): Doğruluk ve hatırlama arasındaki dengeyi ölçer.
- mAP@50:95 (COCO ölçütü): Farklı IoU eşiklerinde tespit performansını değerlendirir.
- Kesinlik (Precision): Doğru şekilde tanımlanan nesnelerin yüzdesini ölçmektedir. Kesinlik hesaplaması Denklem 2'de görülmektedir.

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

- Geri Çağırma (Recall): Tüm ilgili nesnelerin tespit edilme yeteneğini değerlendirir. Denklem 3'te geri çağırma ait hesaplama görülmektedir

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (3)$$

- Saniye Başına Kare (FPS): Her bir modelin gerçek zamanlı işleme kapasitesini ölçer.
- Gecikme (milisaniye): Her çıkarım adımının alacağı süreyi gösterir.
- Karekök Ortalama Hata (RMSE): Mesafe ölçüm hatalarının ortalama büyüklüğünü belirler. RMSE'ye ait hesaplama Denklem 4'te görülmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - \hat{d}_i)^2} \quad (4)$$

Burada n toplam derinlik ölçüm sayısını, d_i yer gerçek derinlik değerini ve $\hat{d}_i$ ise tahmin edilen derinlik değerini temsil etmektedir. Bu ölçütlerin birleşimi, nesne tespiti çerçevesinin doğruluğunun ve gerçek zamanlı demiryolu güvenlik sistemlerinde uygulanabilirliğinin kapsamlı bir şekilde değerlendirilmesini sağlar.

3. Bulgular

Bu bölüm, demiryolu ortamlarında nesne tespiti için önerilen derin öğrenme yöntemlerinin deneysel sonuçlarını sunmakta olup, mesafe ölçümü için ZED kamerasının entegrasyonunun değerlendirilmesini içermektedir.

3.1. Gerçekleştirilen deneyler

Önerilen yöntemlerin performansını değerlendirmek için, RailSem19 veri seti kullanılarak bir dizi deney gerçekleştirilmiştir. Deneyler, dört nesne tespiti modelinin performansını karşılaştıracak şekilde tasarlanmıştır: YOLOv8, YOLOv9, YOLOv11 ve Faster R-CNN. Ayrıca, mesafe ölçümü için ZED kamerasının entegrasyonu, gerçek dünya demiryolu senaryolarında test edilmiştir. Tüm modeller, Metot 'ta açıklandığı şekilde ön işleme tabi tutulan RailSem19 veri seti kullanılarak eğitilmiştir. Performansları, doğruluk, geri çağırma, F1 skoru, mAP50 ve mAP50-95 gibi standart metrikler kullanılarak değerlendirilmiştir. Eğitim süreci, bir NVIDIA Tesla T4 GPU üzerinde gerçekleştirilmiş, çıkarım testleri ise bir NVIDIA RTX 2070 GPU üzerinde yapılmıştır.

3.2. Sayısal sonuçlar

Her modelin performans metrikleri Tablo 1'de özetlenmiştir. Sonuçlar, her yaklaşımın güçlü ve zayıf yönlerini vurgulamakta ve demiryolu ortamlarındaki nesne tespiti görevlerinde etkinliklerinin kapsamlı bir karşılaştırmasını sunmaktadır.


Tablo 1. Modellerin performans metrikleri

Model	Döngü Sayısı	Kesinlik	Geri Çağırma	F1-Skoru	mAP50	mAP50-95	Eğitim Zamanı
YOLOv11	50	0,63409	0,46402	0,53672	0,50412	0,32043	2s 52dk
YOLOv9	25	0,68196	0,46181	0,55017	0,52141	0,33722	2s 4dk
YOLOv8	50	0,67661	0,45112	0,54002	0,49569	0,31709	3s 14dk
Faster R-CNN	25	-	-	-	0,395	0,176	2s 45dk


- YOLOv9, en yüksek kesinlik (0.68196) ve F1-skoru (0.55017) ile test edilen YOLO varyantları arasında en doğru model olmuştur.
- YOLOv11, geri çağırma ve mAP@50-95 açısından YOLOv8'i geride bırakmış, bu da zorlu senaryolarda geliştirilmiş bir dayanıklılığı işaret etmektedir.
- Faster R-CNN, yalnızca %39,5 mAP@50 ile belirgin bir şekilde daha düşük performans sergilemiştir; bu, iki aşamalı tespit sürecinin, RailSem19 veri setinin gerçek zamanlı gereksinimleri ve sınıf dengesizliği ile uyumsuz olmasından kaynaklanmaktadır.
- Roboflow 3.0, daha uzun eğitim süresi (16 saat) olmasına rağmen, hafifçe daha iyi bir kesinlik (0.65) elde etmiştir, ancak hesaplama açısından pahalıdır.

3.3. Görselleştirme


Modelin performansını daha ayrıntılı değerlendirmek için, örnek görüntüler için tespit sonuçları görselleştirilmiştir. Şekil 6'daki görseller, YOLOv8, YOLOv9 ve YOLOv11'in tespit çıktılarının yanı sıra, mesafe ölçümü için ZED kamerasının kullanımına dair niteliksel bir karşılaştırma sunmaktadır. Modeller, çeşitli aydınlatma koşulları, engellemeler ve perspektifler göz önünde bulundurularak farklı test görüntüleri üzerinde değerlendirilmiştir. Bu görselleştirmeler, her modelin gerçek dünya senaryolarındaki güçlü yönlerini ve sınırlamalarını vurgulamaktadır.



a)



b)




c)



ç)



d)



e)

Şekil 6. Görselleştirme sonuçları a) YOLOv11 tespit örneği b) YOLOv9 tespit örneği c) YOLOv8 tespit örneği ç) Roboflow 3.0 tespit örneği d) Mesafe ölçümü YOLOv8 ve ZED2 kamera kullanarak e) Mesafe ölçümü YOLOv8 ve ZED2 kamera kullanarak

ZED kamerası, derinlik verileri kullanarak nesne mesafelerinin tahmin edilmesinde kullanılmıştır. İdeal koşullarda, mesafe ölçümleri $\pm\%5$ doğrulukla yapılmıştır. Ancak, aşırı aydınlatma koşulları ve hızlı hareket eden nesnelerle performans düşüşü gözlemlenmiştir. ZED kamerasından gerçek zamanlı derinlik tahmini, durum farkındalığını artırmak amacıyla YOLO tabanlı modellerle entegre edilmiştir.

3.4. Tartışma

YOLOv9 modeli, yüksek doğruluk, yüksek hassasiyet ve F1-skorları ile olağanüstü bir performans sergilemiş ve Roboflow 3.0'a kıyasla eğitim süresi açısından en verimli model olmuştur. YOLOv9 ve YOLOv11, gerçek zamanlı çıkarım hızlarına ulaşmış ve YOLOv11, doğruluk ve hız arasında en iyi dengeyi sunmuştur. ZED kamerasının entegrasyonu, %5'ten daha az bir ortalama hata ile güvenilir derinlik tahmini sağlamış ve bu, sistemin demiryolu güvenliği uygulamaları için uygunluğunu artırmıştır. ZED kamerası ile elde edilen mesafe bilgileri, yalnızca nesnenin konumunu değil, aynı zamanda bu nesnenin trenin hareketine göre oluşturduğu potansiyel tehlike düzeyini de belirlemektedir. Bu bilgiler, trenin frenleme mesafesine göre engelin konumunu değerlendirerek sistemin kritik uyarılar üretmesini ve gerektiğinde otomatik tepki mekanizmalarını (örneğin, yavaşlama veya durdurma sinyali) devreye almasını sağlamaktadır. Bu yönüyle ZED kamerasının entegrasyonu, yalnızca tespit değil, aynı zamanda durumsal farkındalık ve karar destek süreçlerine katkı sağlayarak literatürdeki önemli bir boşluğu doldurmaktadır.

RailSem19 veri setindeki sınıf dengesizliği, özellikle sinyaller ve yayalar için, model performansını sınırlamıştır. YOLO modelleri hesaplama açısından verimli olsa da kenar cihazlarına dağıtım için daha fazla optimizasyon gerekmektedir. Faster R-CNN'in yüksek kaynak talepleri ve alt optimal performansı, daha hızlı mimarilerin gerekliliğini pekiştirmiştir. Düşük ışık koşulları ve engellemeler altında, yanlış sınıflandırmalar ve atlanan tespitler gibi hata durumları gözlemlenmiştir.

Önerilen yöntemler, doğruluk ve hız açısından önceki yaklaşımlardan daha üstün performans sergilemektedir. Genel nesne tespiti ve diğer alanlarda yapılan araştırmalar, YOLO tabanlı modellerin geleneksel yöntemlere göre daha yüksek doğruluk ve hız sunduğunu göstermektedir [23, 24]. ZED kamerasının mesafe ölçümü için yenilikçi entegrasyonu, demiryolu güvenliği sistemlerinde önemli bir boşluğu doldurmuş ve mevcut YOLO tabanlı demiryolu tespiti yöntemlerine kıyasla önemli iyileştirmeler sunmuştur. Gerçek zamanlı uygulama potansiyeli açısından, sistemin kamera entegrasyonu ve ön işleme süreçlerinden kaynaklanabilecek toplam gecikme dikkate alınmış ve yapılan gözlemler doğrultusunda bu sürenin, gerçek zamanlı demiryolu hat kontrolü uygulamaları için uygun bir düzeyde olduğu değerlendirilmiştir.

4. Sonuç

Bu çalışma, demiryolu ortamları için derin öğrenme tabanlı nesne tespiti modelleri geliştirmiş ve mesafe ölçümü için ZED stereo kamerasını entegre etmiştir. YOLOv8, YOLOv9, YOLOv11 ve Faster R-CNN modellerinin karşılaştırmalı analizi, YOLOv9'un doğruluk ve verimlilik arasında en iyi dengeyi sağladığını göstermiştir. Sonuçlar, otonom demiryolu taşımacılığı ve güvenlik sistemleri gibi uygulamalarda gerçek zamanlı demiryolu izleme olanağının uygulanabilirliğini vurgulamaktadır. Ancak, sınıf dengesizliği ve hesaplama kısıtlamaları gibi zorluklar devam etmektedir. Gelecekteki çalışmalar, GAN tabanlı veri artırma, yapay zekâ destekli model yorumlana bilirliliği ve çoklu sensör füzyonunu keşfederek dayanıklılığı ve genelleme yeteneğini artırmayı amaçlayacaktır. Çalışmada ayrıca, ZED stereo kamerası ile nesnelerin mesafe ölçümleri gerçekleştirilmiş ve derinlik tahminlerinin doğruluğu analiz edilmiştir. Elde edilen sonuçlar, stereo görüş tabanlı derinlik tahmininin nesne tespiti modelleri ile birleştirildiğinde, demiryolu güvenliği sistemlerinde durumsal farkındalığın önemli ölçüde artırılabilirliğini göstermektedir. Bununla birlikte, düşük ışık koşulları ve hızlı hareket eden nesnelerin bulunduğu senaryolarda, derinlik tahmin doğruluğunda düşüşler gözlemlenmiştir. Sonuç olarak, bu çalışma, derin öğrenme tabanlı nesne tespit sistemlerinin demiryolu güvenliği alanında nasıl uygulanabileceğine dair kapsamlı bir analiz sunmuştur. YOLO tabanlı modellerin sağladığı yüksek işlem hızları ve doğruluk oranları, demiryolu ortamlarında proaktif güvenlik önlemlerinin geliştirilmesine olanak

tanımlanmaktadır. Gelecekteki araştırmalar, bu modellerin daha geniş ölçekli senaryolarda test edilmesi ve otonom tren sistemleri ile entegrasyonuna odaklanarak, küresel demiryolu güvenliği alanında yenilikçi çözümler sunabilir.

Kaynakça

- [1] Z. Zhang, P. Chen, Y. Huang, L. Dai, F. Xu, and H. Hu, "Railway obstacle intrusion warning mechanism integrating YOLO-based detection and risk assessment," *J Ind Inf Integr*, vol. 38, pp. 100571, Mar. 2024, doi: 10.1016/J.JII.2024.100571
- [2] A. Katham Mtashre, D. Mohsin Kareem, and Z. Abd Al-Abbas Muhsen, "Enhancing Object Detection Techniques Through Transfer Learning and Pre-trained Models," *Journal of Engineering Sciences and Information Technology (JESIT)*, vol. 3, no. 8, pp. 39–45, Sep. 2024, doi: 10.26389/AJSRP.K270724
- [3] A. Sychugov, V. Miheychikov, and M. Chernyshov, "Application of Neural Networks for Object Recognition in Railway Transportation," *Izvestiâ Peterburgskogo universiteta putej soobšeniâ*, vol. 20, no. 2, pp. 478–491, Jun. 2023, doi: 10.20295/1815-588X-2023-2-478-491
- [4] J. Zhao and M. Su, "Comparative Performance Analysis of Single-Shot Detector and Faster R-CNN for Object Detection," *Computer Science, Engineering and Information Technology*, pp. 209–222, Oct. 2024, doi: 10.5121/CSIT.2024.141919
- [5] M. Sevi and İ. Aydın, "Detection of Foreign Objects Around the Railway Line with YOLOv8," *Computer Science*, no. IDAP-2023, pp. 19–23, Oct. 2023, doi: 10.53070/BBD.1346317
- [6] C. Yong, W. Zhen, and Z. Fangchun, "Railway foreign object tracking and detection with spatial positioning and feature generalization enhancement," *Journal of Applied Artificial Intelligence*, vol. 1, no. 3, pp. 260–274, Oct. 2024, doi: 10.59782/AAI.V1I3.329
- [7] N. Bilous, V. Malko, M. Frohme, and A. Nechyporenko, "Comparison of CNN-Based Architectures for Detection of Different Object Classes," *AI 2024*, vol. 5, no. 4, pp. 2300–2320, Nov. 2024, doi: 10.3390/AI5040113
- [8] S. Ning, F. Ding, and B. Chen, "Research on the Method of Foreign Object Detection for Railway Tracks Based on Deep Learning," *Sensors*, vol. 24, no. 14, p. 4483, Jul. 2024, doi: 10.3390/S24144483
- [9] A. Selvi, S. G. Ragul Ram, K. Sharanraj, and K. Thirukumaran, "AI Precision on Rails Advanced Object Recognition for Train Track Safety - A Survey," *Proceedings - 2024 5th International Conference on Intelligent Communication Technologies and Virtual Mobile Networks*, Tirunelveli, India, 2024, pp. 388–394.
- [10] H. Xianzhi, "Rail traffic distance measurement system and method," 2025. [Online]. Available: <https://typeset.io/papers/rail-traffic-distance-measurement-system-and-method-3wci1a2uub>
- [11] M. Nitti et al., "3d stereo reconstruction of train paths for supporting maintenance operations," *EGU General Assembly Conference Abstracts*, Mar. 2020, doi: 10.5194/EGUSPHERE-EGU2020-20265
- [12] H. K. Drizi and M. Boukadoum, "CNN Model with Transfer learning and Data Augmentation for Obstacle Detection in Rail Systems," *Proceedings - IEEE International Symposium on Circuits and Systems*, Singapore, Singapore, 2024, pp. 1-5.
- [13] X. Wang, J. Yin, F. Pu, X. Chen, A. D'Ariano, and T. Tang, "A GAN-based Deep Learning Model for the Object Detection of Autonomous High-Speed Trains," *Proceedings - 2023 China Automation Congress*, Chongqing, China, 2023, pp. 4393–4398.
- [14] M. F. Nicolas and D. B. Megherbi, "Hidden Challenge in Deep-Learning Real-Time Object Detection on Edge Devices," *Midwest Symposium on Circuits and Systems*, Springfield, MA, USA, 2024, pp. 547–551.
- [15] H. Song, X. Song, M. Zhou, L. Liu, and H. Dong, "Unsupervised Deep Learning-Based Point Cloud Detection for Railway Foreign Object Intrusion," *2024 IEEE 19th Conference on Industrial Electronics and Applications*, Kristiansand, Norway, 2024, pp. 1-6.
- [16] M. A. R. Alif and M. Hussain, "Lightweight Convolutional Network with Integrated Attention Mechanism for Missing Bolt Detection in Railways," *Metrology*, vol. 4, no. 2, pp. 254–278, May 2024. doi: 10.3390/METROLOGY4020016
- [17] N. T. Pham, A. N. Timofeev, and I. S. Nekrylov, "Study of the errors of stereoscopic optical-electronic system for railroad track position," *In Optical Measurement Systems for Industrial Inspection XI*, vol. 11056, pp. 622–635, Jun. 2019, doi: 10.1117/12.2526081
- [18] O. Zendel, M. Murschitz, M. Zeilinger, D. Steininger, S. Abbasi, and C. Beleznaï, "RailSem19: A dataset for semantic rail scene understanding," *IEEE Computer Society Conference on Computer*

- Vision and Pattern Recognition Workshops*, vol. 2019-June, pp. 1221–1229, Jun. 2019, doi: 10.1109/CVPRW.2019.00161
- [19] N. Jegham, C. Y. Koh, M. Abdelatti, and A. Hendawi, “YOLO Evolution: A Comprehensive Benchmark and Architectural Review of YOLOv12, YOLO11, and Their Previous Versions,” arXiv preprint arXiv:2311.10041, 2023.
- [20] S. Y. Rhyou, M. Yu, and J. C. Yoo, “Mixture of expert-based SoftMax-weighted box fusion for robust lesion detection in ultrasound imaging,” *Diagnostics*, vol. 15, no. 5, p. 588, 2025.
- [21] Y. Ji, D. Zhang, Y. He, J. Zhao, X. Duan, and T. Zhang, “Improved YOLO11 algorithm for insulator defect detection in power distribution lines,” *Electronics*, vol. 14, no. 6, p. 1201, 2025.
- [22] F. Saeed, A. Paul, and S. Rho, “Faster R-CNN based fault detection in industrial images,” in *Trends in Artificial Intelligence Theory and Applications. Artificial Intelligence Practices: Proc. 33rd Int. Conf. on Industrial, Engineering and Other Applications of Applied Intelligent Systems (IEA/AIE 2020)*, Kitakyushu, Japan, Sep. 22–25, 2020, pp. 280–287, Springer.
- [23] O. Rodríguez-Abreo, M. A. Quiroz-Juárez, I. Macías-Socarras, J. Rodríguez-Reséndiz, J. M. Camacho-Pérez, G. Carcedo-Rodríguez, and E. Camacho-Pérez, “Automatic detection of railway faults using neural networks: A comparative study of transfer learning models and YOLOv11,” *Infrastructures*, vol. 10, no. 1, p. 3, 2024.
- [24] S. Y. Nikouei, Y. Chen, S. Song, R. Xu, B. Y. Choi, and T. Faughnan, “Smart surveillance as an edge network service: From Haar-cascade, SVM to a lightweight CNN,” in *Proc. 2018 IEEE 4th Int. Conf. on Collaboration and Internet Computing (CIC)*, Philadelphia, PA, USA, Oct. 2018, pp. 256–265.

Özgeçmiş**Muhammed Amir ELMUHAMMEDCEBBEN**

1997 Halep doğumlu. 2023 yılında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü'nden mezun oldu. Halen Fırat Üniversitesinde derin öğrenme ve bilgisayarlı görme üzerine yüksek lisans eğitimine devam etmektedir.

E-Posta: ajabban.edu@gmail.com

**İlhan AYDIN**

1981 yılında Elâzığ'da doğdu. Lisans ve Yüksek Lisans derecelerini Fırat Üniversitesi Bilgisayar Mühendisliğinde 2001 ve 2006 yıllarında aldı. Doktora derecesini 2011 yılında Fırat Üniversitesi, Elâzığ Elektrik ve Elektronik Mühendisliği bölümünden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği bölümünde Profesör olarak görev yapmaktadır. Araştırma alanları arasında optimizasyon, gerçek zamanlı sistemler, hata teşhisi ve durum izleme, sinyal ve görüntü işleme ve derin öğrenme bulunmaktadır.

E-Posta: iaydin@firat.edu.tr

**Mehmet SEVİ**

1988 yılında Denizli'de doğdu. Lisans derecesini Doğu Akdeniz Üniversitesi Bilgisayar Mühendisliğinde, Yüksek Lisans ve Doktora derecesini ise Fırat Üniversitesi Bilgisayar Mühendisliği Bölümünde aldı. Araştırma alanları arasında görüntü işleme ve derin öğrenme bulunmaktadır. Aynı zamanda Muş Alparslan Üniversitesi Bilgi İşlem Daire Başkanlığında çalışmaktadır.

E-Posta: m.sevi@alparslan.edu.tr

Beyanlar:

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Yazarların katkıları: Muhammed Amir ELMUHAMMEDCEBBEN: Metot, Kaynaklar, Görselleştirme, Yazma-orijinal taslak hazırlama. İlhan AYDIN: Kontrol, Yazma-gözden geçirme ve düzenleme, İnceleme. Mehmet SEVİ: Kontrol, Yazma-gözden geçirme ve düzenleme, İnceleme.