



Derin Öğrenme Yöntemleri ile Demiryolu Bağlantı Elemanlarının Sınıflandırılması

Mehmet Sevi^{1*}, İlhan Aydın², Mehmet Karaköse²

^{1*} Muş Alparslan Üniversitesi, Bilgi İşlem Daire Başkanlığı, Muş, Türkiye, (ORCID: 0000-0001-6952-8880), m.sevi@alparslan.edu.tr

² Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0001-6880-4935, ORCID: 0000-0002-3276-3788), iaydin@firat.edu.tr, mkarakose@firat.edu.tr

(İlk Geliş Tarihi 29 Kasım 2021 ve Kabul Tarihi 24 Mart 2022)

(DOI: 10.31590/ejosat.1029905)

ATIF/REFERENCE: Sevi, M., Aydın, İ. & Karaköse, M. (2022). Derin Öğrenme Yöntemleri ile Demiryolu Bağlantı Elemanlarının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 268-274.

Öz

Demiryolu taşımacılığının güvenliğini sağlamada, bilgisayarlı görmeye dayalı yöntemler, demiryolu güvenliğini sağlamak için önemli bir hale gelmiştir. Artan demiryolu trafiği demiryolu bileşenlerin de kısmen aşınmaya ve ciddi kazalara neden olabilmektedir. Demiryolu hattındaki kusurlarının tespit edilmesi önemli bir konu haline gelmiştir. Bu çalışmada, demiryolu bağlantı elemanlarındaki kusurların sınıflandırılması için derin öğrenme tabanlı bir sistem önerilmiştir. Önerilen yaklaşım, sağlıklı demiryolu bağlantı elemanı görüntülerini kullanarak kusurlu veriler üretmektedir. Yeni görüntü elde etmek için bir görüntü bölütleme yöntemi kullanılmıştır. Ardından derin öğrenme modelleriyle sağlıklı ve kusurlu demiryolu bağlantı elemanı görüntüleri sınıflandırılmıştır. Bölütleme işlemi için Unet modeli kullanılmıştır. Veri seti eğitimi ve bağlantı elemanlarının kusurlarını sınıflandırmak için CNN, VGG-16 ve ResNet50 modelleri kullanılmıştır. Önerilen yöntem literatürdeki diğer modellerle karşılaştırılmış ve sınıflandırma performansı açısından daha iyi sonuçlar elde edilmiştir. Önerilen yöntem %100 doğruluk oranı yakalamıştır.

Anahtar Kelimeler: Demiryolu, Demiryolu Bağlantı Elemanları, Kusur Tespiti, Bilgisayarlı Görme, Unet, Derin Öğrenme Algoritmaları.

Classification of Railway Fasteners by Deep Learning Methods

Abstract


In ensuring the safety of railway transport, computer vision-based methods have become important to ensure railway safety. Increased rail traffic can cause partial wear of railway components and serious accidents. Detection of defects in the railway line has become an important issue. In this study, a deep learning-based system is proposed for the classification of defects in defective fasteners. The proposed approach produces defective data using healthy rail fastener images. An image segmentation method was used to obtain a new image. Then, healthy and defective railway fastener images were classified with deep learning models. The Unet model was used for the segmentation process. CNN, VGG-16, and ResNet50 models were used to train the dataset and classify the defects of the fasteners. The proposed method was compared with other models in the literature and better results were obtained in terms of classification performance. The proposed method has achieved 100% accuracy.

Keywords: Railways, Fastener, Defect Detection, Computer Vision, Unet, Deep Learning Algorithms.

* Sorumlu Yazar: m.sevi@alparslan.edu.tr

1. Giriş

Bir yerden bir yere madeni bir yol üzerinde, mekanik bir güçle hareket ettirilen madeni tekerlekli araçlar içerisinde, insan veya eşya taşınmasını sağlayan tesislerin tümüne birden demiryolu denmektedir. Demiryolu taşımacılığı günümüzün en önemli ulaşım türlerinden biri haline gelmiştir. Hızlı trenlerin gelişmesi demiryolu ulaşımına olan talebi arttırmıştır. Demiryolu ulaşımının kalitesi güvenliğiyle doğru orantılıdır. Bu nedenle demiryolu bileşenlerindeki kusurların tespiti son derece önemli hale gelmiştir. Demiryolu taşımacılığında araçların (tren, vagon) tekerlekleri ile üzerinde hareket ettikleri paralel biçimde yerleştirilmiş metal çubuklara ise ray denilmektedir. Demiryolu hattı birçok bileşenden oluşmaktadır. Demiryolu hattının temel bileşenleri Şekil 1'de verilmiştir.



Şekil 1. Demiryolu bileşenleri (Figure 1. Railway components)

Şekil 1'de görülen balastlar, platforma gelecek yükleri geniş bir alana yaymaktadır. Travers, raylardan gelen yükleri balasta aktarmak amacıyla belli aralıklarla balast üzerine yerleştirilmiş ahşap, demir veya betondan yapılmış elemanlardır. Bağlantı elemanları ise iki ray arasındaki travers ile rayları birbirine bağlayan ve rayın enlemesine hareketlerini önleyen, çelik çiviler tarafından tutulan bileşenlerdir (Clark, 2004). Bağlantı elemanları rayın iç ve dış kısmında bulunmaktadır. Bu bileşenlerdeki problemler erken bir aşamada tespit edilmezse ciddi kazalara neden olabilir. Demiryollarının güvenliği için, iyi eğitilmiş personelin demiryolu bileşenlerini sürekli kontrol etmeleri gerekmektedir. Bu da büyük zaman ve yüksek işçilik maliyeti oluşturmaktadır. Çalışmada bu problemi gidermek için derin evrimsel sinir ağına (DCNN) dayalı otomatik tespit sistemi önerilmiştir. Ancak demiryolu bağlantı elemanlarının kusurlarını içeren veri setleri genelde dengesizdir. Bu çalışmada kusurlu bağlantı elemanları arızalı ve eksik olarak iki gruba ayrılmıştır. Dengesiz veri setlerinde kusurlu bağlantı elemanlarını içeren görüntü sayısı sağlıklı görüntülere göre oldukça azdır. Bu durumu dengelemek için sağlıklı bağlantı elemanlarını kullanarak yeni kusurlu görüntüler oluşturmak amaçlanmıştır. Bunun için anlamsal bölütleme yöntemini kullanarak yeni kusurlu bağlantı elemanları oluşturulmuştur. Daha sonra elde edilen görüntülere bilgisayarlı görme ve derin öğrenme tabanlı teknikler uygulanarak bağlantı elemanları kusurlarına göre sınıflandırılmıştır. Liu ve ark. geliştirdikleri kusurlu görüntülere dayalı demiryolu bağlantı elemanlarını inceleme işleminde %97'lik başarı sağlamışlardır (Liu, 2021). Geliştirdikleri sistemle az sayıdaki kusurlu görüntüleri yapay olarak çoğaltarak daha iyi bir çalışma ortamı sağlamışlardır. Bir diğer çalışmada Guo ve ark. kayıt altına alınan video görüntülerden ray bileşenlerini içerdikleri kusurlara göre incelemişlerdir (Guo, e-ISSN: 2148-2683

2021). Bu işlemi hibrit bir YOLOv4 sinir ağı ile yapmışlardır. Diğer tek aşamalı nesne algılama modelleriyle karşılaştırıldığında, YOLOv4 hibrit modeli hem doğruluk hem de işleme hızı açısından diğer modellerden daha iyi performans göstermiş ve %94,4 ortalama hassasiyet (mAP) değeri yakalamıştır. Bir diğer çalışmada Gibert ve ark. derin evrimsel sinir ağları (DCNN) ve anlamsal bölütleme kullanarak demiryolu bileşenlerinde kullanılan malzemeleri sınıflandırmayı amaçlamışlardır (Gibert, 2017). Önerilen yaklaşım 10 malzeme sınıfını kullanarak %93,35 doğruluk oranı yakalamıştır. Demiryolu güvenliği açısından ray bileşenleri üzerindeki kusurların tespit edilmesi günümüz kusur tespit sistemleriyle zaman kaybettiren bir süreçtir. Günümüzde elle sürdürülen bu süreç yerine var olan teknolojik olanaklardan faydalanarak kusurları tespit edebilmek için zaman ve maliyet açısından avantajlı sistemler geliştirilmektedir. (Min, 2018). Literatürde yapılan çalışmalarda derin öğrenme modellerinin ray bileşenleri üzerindeki kusurları tespit etmede başarılı oldukları ispatlanmıştır (Qi, 2020). Bir diğer çalışmada geliştirilen YoloV4-Bulanık Mantık yöntemi ile bağlantı elemanları %99 doğruluk oranıyla sınıflandırılmıştır. Bağlantı elemanları sağlıklı ve kusurlu olmak üzere iki sınıfa ayrılmıştır (Güçlü, 2021). Ray yüzeyindeki kusurları tespit eden çalışmada, ray yüzeyindeki kusurları sınıflandıran füzyon bir model önerilmiştir. Eğitim ve test işleminden önce veri setindeki ham görüntülere kontrast iyileştirme ve konum belirleme yöntemleri uygulanmıştır. SqueezeNet ve MobileNetV2 gibi derin öğrenme modellerinin özellikleri birleştirilerek yüksek doğrulukta bir füzyon modeli önerilmiştir. Önerilen model %97'lik doğruluk oranı yakalamıştır (Aydın, 2021).

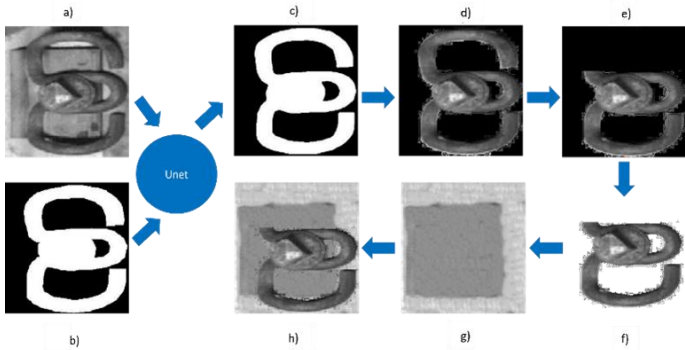
Çalışmada Demiryolu Araştırma ve Teknoloji Merkezinden (DATEM) alınan demiryolu bağlantı elemanları görüntülerine öncelikle anlamsal bölütleme işlemi uygulanarak veri setini genişletmek amaçlanmıştır. Daha sonra elde edilen yeni kusurlu demiryolu bağlantı elemanı görüntüleri derin öğrenme modelleri ile eğitilerek sınıflandırma işlemi tamamlanmıştır. Çok etiketli bir sınıflandırma yapılmıştır. Çalışmanın ikinci kısmında önerilen yöntemden ve değerlendirme metriklerinden, üçüncü kısımda ise veri setinden ve sınıflandırma sonuçlarından bahsedilecektir. Son bölümde ise çalışmanın genel sonucuna değinilecektir.

2. Materyal ve Metot

Bu çalışmada, dengesiz veri seti üzerinde demiryolu bağlantı elemanlarının ne tür kusur içerdiklerini tespit etmek için yeni bir yöntem önerilmiştir. Önerilen yöntem iki aşamadan oluşmaktadır. Birinci aşamada, kusurlu veri oluşturma yöntemi ile arızalı ve eksik bağlantı elemanı örnekleri üretilmiştir. İkinci kısımda ise önerilen CNN, VGG-16 ve ResNet50 modelleri ile kusurlu bağlantı elemanlarını sınıflandırmak amaçlanmıştır. Önerilen kusurlu veri üretim diyagramı Şekil 2'de gösterilmektedir.

Dış mekân sahnelerinde çekilen görüntüler, zayıf aydınlatma koşulları nedeniyle büyük ölçüde bozuk olabilmektedir. Bu görüntüler, bilgisayarlı görme algoritmalarının genel performansını etkileyen yüksek gürültü seviyelerine sahip olabilirler. Düşük aydınlatma koşullarında bilgisayarlı görme algoritmalarını sağlam hale getirmek için, bir görüntünün görünürlüğünü iyileştirmek gerekmektedir. Bu sebepten dolayı düşük ışıkta görüntü geliştirme yöntemi kullanılmıştır. Düşük ışıklı görüntüleri geliştirmek için pus

giderme teknikleri kullanılmıştır. Bu sayede veri setindeki düşük aydınlatma koşullarında alınan sağlıklı demiryolu bağlantı elemanları sınıflandırma için uygun hale getirilmiştir. Demiryolu veri setlerinde, kusurlu bağlantı elemanlarının sayısı sağlıklı bağlantı elemanlarına göre oldukça azdır ve kusurlu veriye erişmek oldukça zordur. Bu nedenle sağlıklı ve kusurlu bağlantı elemanlarının sayısını dengelemek için Unet tabanlı bir model önerilmiştir. GrabCut algoritması, Unet modelinin ürettiği görüntüyü ve orijinal sağlıklı bağlantı elemanına ait görüntüyü kullanarak, görüntüdeki bağlantı elemanının ön plana çıkarılmasını sağlamıştır. GrabCut, bölütlemeyi iyileştirmek ve görüntüdeki nesneyi ön plana çıkarmak için yinelemeli olarak grafik kesimleri için uygulanmaktadır. Bu sayede sağlıklı ve kusurlu bağlantı eleman sayısı eşitlenmiş ve daha verimli bir sınıflandırma modeli oluşturulmuştur.




Şekil 2. Kusurlu bağlantı elemanı üretimi a) Sağlıklı bağlantı elemanı b) Sağlıklı referans veri c) Unet bölütleme sonucu d) Grabcut ile ön plana çıkarılmış bağlantı elemanı e) Yeni üretilen kusurlu bağlantı elemanı f) Şeffaflaştırılmış kusurlu bağlantı elemanı g) Varsayılan arka plan h) Varsayılan arka plan eklenmiş kusurlu bağlantı elemanı (Figure 2. Defective fastener production a) Healthy fastener b) Healthy reference data c) Unet segmentation result d) Grabcut highlighted connector e) Newly produced defective fastener f) Transparent rendered defective fastener g) Default background h) Defective fastener with default background added)

Unet, otomatik bir görüntü bölütleme yöntemidir. Unet, Ronneberger ve arkadaşları tarafından biyomedikal resim bölütleme için tasarlanmıştır (Ronneberger, 2015). Unet, farklı mimari ve evrişimli sinir ağı katmanlarından oluşan piksel tabanlı görüntü bölütleme yöntemidir. Klasik modellere göre daha başarılı sonuçlar vermektedir. Az sayıda görüntü içeren veri setlerinde de başarılı sonuçlar vermiştir. Unet, adımı U harfine benzeyen mimarisinden almaktadır ve Şekil 3'te görülmektedir. Unet kodlama ve kod çözme kısımlarından oluşmaktadır. Kodlama kısmında görüntüdeki içerik yakalanmaktadır. Maksimum havuzlama katmanlarından oluşmaktadır. Kod çözme kısmı ise, devredilen konvolüsyonları kullanarak hassas lokalizasyonu sağlamak için kullanılan simetrik genişleme yoludur (dekoder olarak da adlandırılır) (Türk, 2019).

Unet modeli sayesinde dengelenen veri seti sınıflandırma için uygun hale getirilmiştir. Veri setindeki bağlantı elemanları sağlıklı ve kusurlu (arızalı ve eksik) olarak sınıflandırılmıştır. Sınıflandırma kısmında VGG-16, ResNet50 ve tarafımızca oluşturulan CNN modelleri kullanılmıştır.

Çalışmada kullanılan VGG-16 24 katmandan oluşmaktadır. VGG-16 ImageNet Challenge 2014'te başarılar kazanan bir derin öğrenme modelidir (Sevi, 2020). Küçük filtreler (3x3) VGG-16'da evrişim katmanlarında kullanılmaktadır (Sevi, 2020).

VGG-16, 13 evrişim katmanı ve 3 tam katmandan oluşmaktadır. 4x4 boyutunda 5 havuz katmanı bulunmaktadır. Son katman softmax katmanından oluşmaktadır. Softmax katmanıyla gelen giriş verileri sınıflandırılmıştır. Relu, aktivasyon fonksiyonu olarak kullanılmıştır.

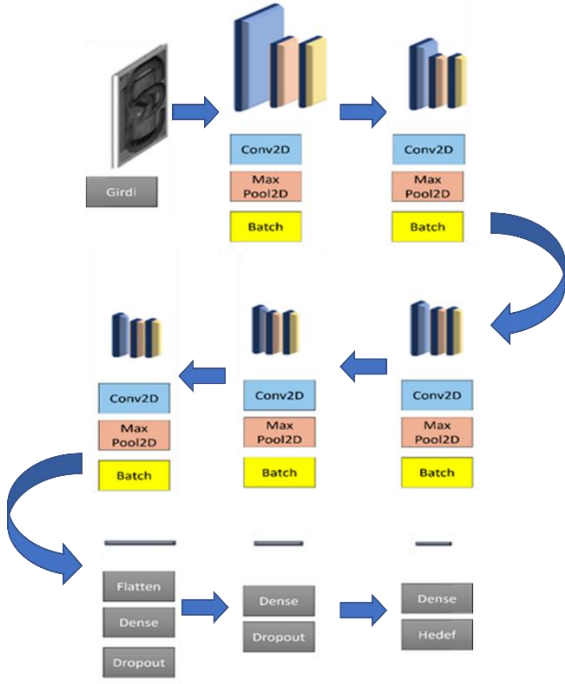


Şekil 3. Unet mimarisi (Figure 3. Unet architecture)

Ayrıca bu modelde hesaplama karmaşıklığında önemli bir faktör olan parametre sayısı diğer ResNet modellerine göre azaltılmıştır. ResNet50 modeli 180 katmandan oluşmaktadır. Aktivasyon fonksiyonu olarak Softmax ve Relu kullanılmıştır.

Evrişimli sinir ağı (CNN), bilgisayarlı görme için kullanılan derin öğrenme ağlarından bir tanesidir. CNN algoritması, hayvanların görsel merkezinden esinlenilerek oluşturulmuştur (Gündüz, 2019). CNN'ler, görüntüleri girdi olarak almak için tasarlanmış yapılar ve bilgisayarlı görmeye etkin bir şekilde kullanılmaktadır. CNN, bir veya daha fazla evrişimli katmandan oluşmaktadır (Gündüz, 2019). Bunlar; giriş katmanı, konvolüsyonel katmanı (convolution), yığın normalleştirme katmanı (batch normalization), düzleştirme katmanı (flatten), havuzlama katmanı (pooling), tam bağlantılı katman (fully connected, dense) ve düğüm seyreltme katmanıdır (dropout).

CNN'de giriş verilerini aldıktan sonra katman katman işlemler yapılarak eğitim süreci gerçekleştirilir (İnik, 2017). Sonunda doğru sonuç ile karşılaştırma yapmak için bir hedef çıktısı verir (İnik, 2017). Üretilen çıktı ile gerçek veri arasında bir hata farkı oluşur. Bu hatayı azaltmak için geriye yayılım algoritması kullanılır. Her bir iterasyonla ağırlıkların güncellenmesi yapılarak hatanın azaltılması sağlanır ve sınıflandırma işleminde başarımlar sağlanmış olur (İnik, 2017). VGG-16 ve ResNet50'de olduğu gibi Softmax ve Relu aktivasyon fonksiyonu kullanılmıştır. Tablo 1'de görüldüğü gibi CNN modeli ResNet50 ve VGG-16 modeline göre daha az parametre ve katman içermektedir. CNN modelinde geleneksel katman yapısına ek olarak yığın normalleştirme ve düğüm seyreltme katmanları eklenmiştir. Düğüm seyreltme (dropout), modelin aşırı öğrenmesini engellemektedir. Tam bağlı katmandaki düğümler arasındaki bağları kopararak ağdaki yanlış bilgilerin unutulmasını sağlamıştır. Böylelikle eğitim performansı artmıştır. Yığın normalleştirme ise konvolüsyonel katmanları arasında kullanılmıştır. Modeli daha düzenli hale getirerek eğitim süresini kısaltmıştır. Eğitim süresi performans kaybı yaşamadan %39 azalmıştır. Şekil 4'te önerilen CNN mimarisi görülmektedir.



Şekil 4. CNN mimarisi (Figure 4. CNN architecture)

Tablo 1. Önerilen modellerinin katman ve parametre sayıları (Table 1. Number of layers and parameters of the suggested models)

Ağ	Yıl	Katman Sayısı	Parametre Sayısı
VGG-16	2014	24	14M
ResNet50	2015	180	24M
Oluşturulan CNN	-	21	0.6M

Tablo 2’te kullanılan derin öğrenme tabanlı modellerin eğitim parametreleri verilmiştir. Tablo 2’de görüldüğü gibi seyreltme değeri önce 0.3, sonra 0.5 olarak seçilmiştir. Modellerin ezberlemesini önlemek için seyreltme değeri kullanılmıştır. Arttırma işleminden sonra model performansında bir düşüş gözlemlenmemiştir.


Tablo 2. Eğitim parametreleri (Table 2. Training parameters)

Ağ	Döngü Sayısı	Mini Batch Boyutu	Öğrenme Oranı	Seyreltme Değeri
VGG-16	20	8	1e-3	0.3, 0.5
ResNet50	20	8	1e-3	0.3, 0.5
Oluşturulan CNN	20	8	1e-3	0.3, 0.5

3. Deneysel Sonuçlar


Demiryolu hattından toplanan sağlıklı bağlantı elemanlarını içeren veri seti veri üretim teknikleri ile dengelenmiştir. Daha sonra derin öğrenme yöntemleri: CNN, VGG-16 ve ResNet50 demiryolu bağlantı elemanlarını içeren dengelenmiş veri setine uygulanmıştır. Çalışmadaki deney ortamı Windows 10 işletim sistemi, Intel(R) Core (TM) i5-1135G7 @ 2.40GHz işlemci, 16 GB bellek ve NVIDIA GeForce MX450 2GB ekran kartı şeklinde ayarlanmıştır. DATEM’den alınan veri seti 534 tane sağlıklı demiryolu bağlantı elemanı içermektedir. Sağlıklı

görüntülere ek olarak 534 tanede arızalı ve eksik demiryolu bağlantı elemanı bölütleme sonucu üretilmiştir. Unet bölütleme modeli yeni bağlantı elemanı elde etmek için eğitilmiştir. Burada eğitim ve doğrulama seti için sırasıyla 0.8 ve 0.2 oranında bağlantı elemanı seçilmiştir. Optimizasyon fonksiyonu olarak Adam seçilmiştir. Eğitim için tur sayısı 120 olarak ayarlanmıştır. Unet mimarisinin doğruluk ve kayıp grafikleri Şekil 5’te görülmektedir.



Şekil 5. Unet öğrenme grafikleri (Figure 5. Unet learning charts)

Şekil 5’te görüldüğü gibi 10. döngüden sonra göze çarpan bir değişiklik olmasa da tur sayısının 120 seçilmesinin nedeni eğitim modelinin aşırı öğrenmeye gitmediğini göstermektedir. Şekil 5’teki kayıp grafiği incelendiğinde kayıp değerinin 0’a yakın olduğu görülmektedir. Bu değer 0’a ne kadar yakınsa eğitimin o kadar başarılı gerçekleştiği anlamı çıkarılabilir. Şekil 6’da Unet ile elde edilmiş görüntü ve bu görüntüden elde edilen arızalı ve eksik demiryolu bağlantı elemanları görülmektedir. Unet modeli %99’luk doğruluk oranı yakalamıştır. Kusurlu verinin bulunamadığı durumlarda sağlıklı demiryolu bileşeni görüntülerini kullanarak kusurlu verilerin elde edilebildiği ispatlanmıştır. Böylelikle veri seti dengelenmiştir.



Şekil 6. Unet sonucu elde edilen görüntüler a) Sağlıklı bağlantı elemanı b) Sağlıklı referans veri c) Bölütleme sonucu d) Ön plana çıkarılmış arızalı bağlantı elemanı e) Ön plana çıkarılmış eksik bağlantı elemanı (Figure 6. Images obtained as a result of Unet a) Healthy fastener b) Healthy reference data c) Segmentation result d) Defective fastener highlighted e) Highlighted missing fastener)

Sınıflandırıcının performansı aşağıdaki dört standart metrik kullanılarak değerlendirilmektedir. Bu metrikler; doğru pozitif (True Positive-TP), yanlış pozitif (False Positive-FP), doğru negatif (True Negative-TN) ve yanlış negatif (False Negative-FN) değerlendirme metrikleridir. (Ekrem, 2020).

$$\text{Doğruluk}(A) = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Duyarlılık}(R) = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Kesinlik}(P) = \frac{TP}{TP+FP} \quad (3)$$

$$F1 = 2 * \frac{P \times R}{P+R} \quad (4)$$

$$\text{Özgüllük}(P) = \frac{TN}{TN+FP} \quad (5)$$

Yukarıdaki metriklerin tümü, karışıklık matrisinden türetilmiştir. Sınıflandırıcının performansını belirlemek için tek

bir metrik yeterli değildir. Doğruluk, tüm sınıflardaki girdi verilerinin performansını ölçmek için ana metriktir. Modelin performansını sadece doğruluk metriği ile ölçmek çoğu zaman yanılgıya yol açabilmektedir. Bundan dolayı oluşturulan modelin performansının değerlendirilmesinde sadece doğruluk metriği değil buna ek olarak kullanılacak metriklere ihtiyaç duyulmaktadır (Alan, 2020). Diğer metrikler her sınıfa özeldir ve ilgili sınıfın sınıflandırma algoritmasında geri çağırma oranını hesaplar. Tablo 3'te VGG-16 mimarisinin performans değerlendirme metrikleri görülmektedir.

Tablo 3. VGG-16 mimarisinin performans metrikleri (Table 3. Performance metrics of the VGG-16 architecture)

Sınıf/Metrik	P	R	F1
Arızalı	1.00	1.00	1.00
Sağlıklı	1.00	1.00	1.00
Eksik	1.00	1.00	1.00
A	100%		
R	1.00		
S	1.00		

Tablo 4'te ResNet50 mimarisinin performans değerlendirme metrikleri görülmektedir.

Tablo 4. ResNet50 mimarisinin performans metrikleri (Table 4. Performance metrics of the ResNet50 architecture)

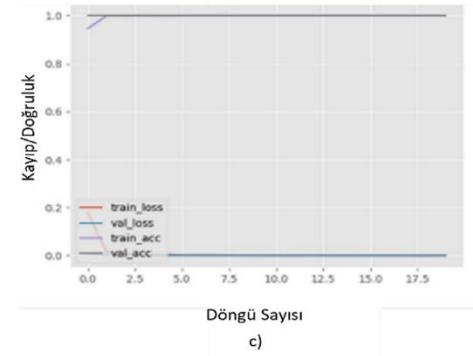
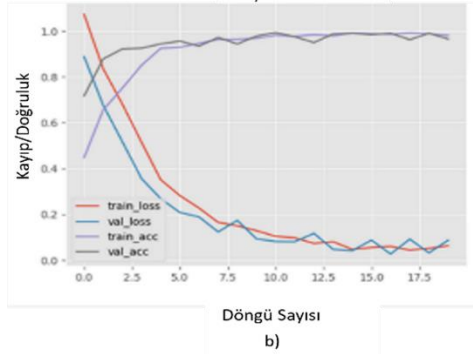
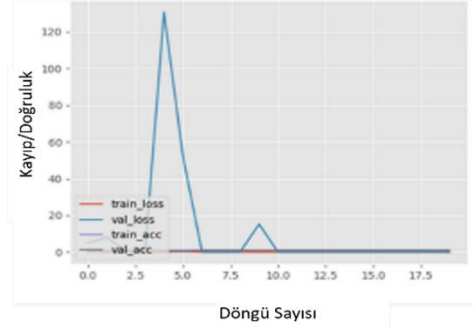
Sınıf/Metrik	P	R	F1
Arızalı	0.94	1.00	0.97
Sağlıklı	1.00	0.94	0.97
Eksik	1.00	1.00	1.00
A	98%		
R	1.00		
S	0.94		

Tablo 5'te oluşturulan CNN mimarisinin performans değerlendirme metrikleri görülmektedir.

Tablo 5. CNN mimarisinin performans metrikleri (Table 5. Performance metrics of CNN architecture)

Sınıf/Metrik	P	R	F1
Arızalı	1.00	1.00	1.00
Sağlıklı	1.00	1.00	1.00
Eksik	1.00	1.00	1.00
A	100%		
R	1.00		
S	1.00		

Tablo 3 ve 5'te görüldüğü gibi, oluşturulan CNN ve VGG-16 mimarileri ResNet50 mimarisine göre daha iyi performans vermiştir. Önerilen bütün modeller yüksek doğruluk oranı yakalamışlardır. Oluşturulan CNN ve VGG-16 modelleri arızalı, eksik ve sağlıklı demiryolu bağlantı elemanlarını %100 doğruluk oranıyla sınıflandırmıştır. Önerilen modellerin öğrenme grafikleri Şekil 7'de görülmektedir.



Şekil 7. Önerilen modellerin öğrenme grafikleri a) CNN b) ResNet50 c) VGG-16 (Figure 7. Learning graphs of the proposed models a) CNN b) ResNet50 c) VGG-16)

Yukarıdaki performans metrikleri seyreltme değeri 0.3 alındığında elde edilmiştir. Seyreltme değerini arttırdığımızda herhangi bir performans kaybı yaşanmamıştır. Sonuçlar Tablo 6'da görülmektedir. Seyreltme katmanı modelin ezberleme yapmasını engellemektedir (Özçelik, 2021).

Tablo 6. Seçilen seyreltme değerine göre başarımlar oranları (Table 6. Success rates according to the selected dropout value)

Model/Metrik	Seyreltme Değeri (0.3)	Seyreltme Değeri (0.5)
CNN (A)	100%	100%
CNN (R)	1.00	1.00
CNN (S)	1.00	1.00
ResNet50 (A)	98%	98%
ResNet50 (R)	1.00	1.00
ResNet50 (S)	0.94	0.94
VGG-16 (A)	100%	100%
VGG-16 (R)	1.00	1.00
VGG-16 (S)	1.00	1.00


Tablo 7. Önerilen modellerin gürültülü ve üretilmiş veri seti üzerindeki performansları (Table 7. Performance of the proposed models on noisy and generated dataset)

Veri seti	Mimari	Etiket / P		Etiket / R		Etiket / F1		A	Döngü Sayısı
Gürültülü Veri Seti	VGG-16	Sağlıklı	1.00	Sağlıklı	1.00	Sağlıklı	1.00	1.00	20
		Arızalı	1.00	Arızalı	1.00	Arızalı	1.00		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		
Gürültülü Veri Seti	ResNet50	Sağlıklı	1.00	Sağlıklı	0.94	Sağlıklı	0.97	0.98	20
		Arızalı	0.95	Arızalı	1.00	Arızalı	0.97		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		
Gürültülü Veri Seti	Oluşturulmuş CNN	Sağlıklı	1.00	Sağlıklı	1.00	Sağlıklı	1.00	1.00	20
		Arızalı	1.00	Arızalı	1.00	Arızalı	1.00		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		
Üretilmiş Veri Seti	VGG-16	Sağlıklı	1.00	Sağlıklı	1.00	Sağlıklı	1.00	1.00	20
		Arızalı	1.00	Arızalı	1.00	Arızalı	1.00		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		
Üretilmiş Veri Seti	ResNet50	Sağlıklı	1.00	Sağlıklı	0.93	Sağlıklı	0.97	0.98	20
		Arızalı	0.94	Arızalı	1.00	Arızalı	0.97		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		
Üretilmiş Veri Seti	Oluşturulmuş CNN	Sağlıklı	1.00	Sağlıklı	1.00	Sağlıklı	1.00	1.00	20
		Arızalı	1.00	Arızalı	1.00	Arızalı	1.00		
		Eksik	1.00	Eksik	1.00	Eksik	1.00		

Tablo 8. Önerilen CNN modelinin literatürdeki modellerle karşılaştırılması (Table 8. Comparison of the proposed CNN model with the models in the literature)

Referans	Model	Etiket / P		Etiket / R		Etiket / F1		A
(Feng, 2013)	Probabilistic structure modeling	Sağlıklı	0.97	Sağlıklı	0.97	Sağlıklı	0.97	0.96
		Arızalı	0.97	Arızalı	0.80	Arızalı	0.81	
		Eksik	0.97	Eksik	0.88	Eksik	0.85	
(Liu, 2019)	Similarity based deep learning method	Sağlıklı	0.85	Sağlıklı	0.85	Sağlıklı	0.85	0.92
		Arızalı	0.98	Arızalı	0.96	Arızalı	0.97	
		Eksik	0.98	Eksik	0.99	Eksik	0.99	
(Dou, 2014)	Template matching based nearest neighbor	Sağlıklı	0.92	Sağlıklı	0.97	Sağlıklı	0.94	0.96
		Arızalı	0.67	Arızalı	0.87	Arızalı	0.75	
		Eksik	0.83	Eksik	0.87	Eksik	0.85	
(Liu, 2021)	Improved Alexnet	Sağlıklı	0.97	Sağlıklı	0.92	Sağlıklı	0.95	0.95
		Arızalı	0.96	Arızalı	1.00	Arızalı	0.98	
		Eksik	1.00	Eksik	0.99	Eksik	0.99	
Önerilen Yöntem	Oluşturulmuş CNN	Sağlıklı	1.00	Sağlıklı	1.00	Sağlıklı	1.00	1.00
		Arızalı	1.00	Arızalı	1.00	Arızalı	1.00	
		Eksik	1.00	Eksik	1.00	Eksik	1.00	

DATEM'den alınan veri seti iyileştirilme ve veri üretim tekniklerinden geçirilmiş daha sonra ise derin öğrenme modelleriyle eğitilmiş ve test edilmiştir. Bölütleme sonucu üretilen verilere sentetik gürültü eklendiğinde önerilen modellerin performanslarında kayba rastlanılmamıştır. Şekil 8'de sentetik gürültü eklenmiş ve bölütleme sonucu oluşturulmuş bağlantı elemanları görülmektedir. Tablo 7'de görüldüğü gibi gürültü ekleme işlemi başarı oranlarına negatif olarak yansımamıştır. Üretilen (arızalı ve eksik bağlantı elemanları) kusurlu görüntülerin farklı çeşitlilikte olması önerilen modellerin başarılı olmasında temel etken olmuştur. Böylelikle gürültülü veri setlerinin performans sorunlarının çözülebileceği kanıtlanmıştır. Önerilen CNN modelinin performansı, literatürdeki temel yaklaşımlarla da karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 8'de verilmiştir.



a) Gürültülü Veri

b) Üretilmiş Veri

Şekil 8. a) Sentetik gürültü eklenmiş bağlantı elemanı b) iyileştirilmiş ve üretilmiş bağlantı elemanı (Figure 8. a) Synthetic noise added fastener b) Improved and manufactured fastener)

4. Sonuçlar

Demiryollarındaki arızaların önceden tespiti her zaman hem ekonomi hem de insan sağlığı için çok önemli bir konu olmuştur. Demiryolu hattındaki arızalı ve eksik bağlantı elemanlarının tespiti en büyük problemlerden bir tanesidir. Bu çalışmada, bu sorunu çözmek için CNN tabanlı yeni bir derin ağ modeli önerilmiştir. Önerdiğimiz modelin iki ana aşaması vardır. İlk olarak, demiryollarından toplanan dengesiz veri seti Unet yardımıyla dengelenmiştir. Sonra ise farklı derin öğrenme modelleriyle arızalı bağlantı elemanları sınıflandırılmıştır. Önerilen CNN mimarisinin iki ana avantajı vardır. Birincisi mimari olarak basittir ve daha az hesaplama süresine ihtiyaç duyar. İkincisi, literatürdeki önemli sınıflandırma modellerine kıyasla daha iyi bir sınıflandırma performansı göstermesidir. Ayrıca bu çalışmada demiryolu hattı üzerindeki bağlantı elemanları ile ilgili yeni bir veri seti oluşturulmuştur. Önerilen modelin performansını doğrulamak için bir dizi deney yapılmıştır. Bu çalışmada ayrıca, önerilen modellerin performansları gürültülü veri seti üzerinde test edilmiş ve önerilen modellerin performanslarında düşüş gözlemlenmemiştir.

5. Teşekkür

Bu çalışma, 120E097 numaralı TÜBİTAK projesi tarafından desteklenmiştir.

Kaynakça

- Clark, R. (2004). Rail flaw detection: overview and needs for future developments. *Ndt & E International* 37. 111-118.
- Liu, J., Teng, Y., Ni, X. & Liu H. (2021). A Fastener Inspection Method Based on Defective Sample Generation and Deep Convolutional Neural Network. *IEEE Sensors Journal*, vol. 21, no. 10, pp. 12179-12188, doi: 10.1109/JSEN.2021.3062021.
- Guo, F., Qian, Y., & Shi, Y. (2021). Real-time railroad track components inspection based on the improved YOLOv4 framework. *Autom. Construct.*, vol. 125, Art. No. 103596.
- Gibert, X., Patel, V. M., & Chellappa, R. (2017). Deep Multitask Learning for Railway Track Inspection. *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 1, pp. 153-164, doi: 10.1109/TITS.2016.2568758.
- Min, Y., Xiao, B., & Dang, J. (2018). Real time detection system for rail surface defects based on machine vision. *EURASIP Journal on Image and Video Processing*, 3. <https://doi.org/10.1186/s13640-017-0241-y>
- Qi, H., Xu, T., Wang, G., Cheng, Y., & Chen C. (2020). MYOLOv3-Tiny: A new convolutional neural network architecture for real-time detection of track fasteners. *Computers in Industry*. 123. 103303. 10.1016/j.compind.2020.103303.
- Güçlü, E., Aydın, İ., Şahbaz, K., Akın, E., & Karaköse M. (2021). Demiryolu bağlantı elemanlarında bulunan kusurların YOLOv4 ve bulanık mantık kullanarak tespiti. *Demiryolu Mühendisliği*, vol. 14, 249-262, doi:10.47072/demiryolu.939830.

Aydın, İ., Akın, E., Karaköse, M. (2021). Defect classification based on deep features for railway tracks in sustainable

transportation. *Applied Soft Computing*, vol. 111, 107706, doi:10.1016/j.asoc.2021.107706.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention* 234-241.

Türk, F., & Lüy, M. (2019). Böbrek Tümör Segmentasyonu İçin Unet ve Unet-ResNet Modellerinin Karşılaştırılması. 1-5. 10.1109/ISMSIT.2019.8932725.

Sevi, M., & Aydın, İ. (2020). COVID-19 Detection Using Deep Learning Methods. *2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI)*, pp. 1-6, doi: 10.1109/ICDABI51230.2020.9325626.

Çetintaş, D. (2019). Derin Öğrenme ve Tıbbi Uygulamaları. *Doktora Semineri, Fırat Üniversitesi*.

Gündüz, G., & Cedimoğlu, İ. H. (2019). Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini. *Sakarya University Journal Of Computer And Information Sciences*, 2, 9-17.

İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*.

Ekrem, Ö., Salman, Ö.K.M., Aksoy, B., & İnan, S.A. (2020). Yapay Zekâ Yöntemleri Kullanılarak Kalp Hastalığının Tespiti. *Mühendislik Bilimleri ve Tasarım Dergisi*, vol. Uluslararası Mühendislikte Yapay Zekâ ve Uygulamalı Matematik Konferansı (UMYMK 2020), pp. 241-254, doi: 10.21923/jesd.824703.

Alan, A., & Karabatak, M. (2020). Veri Seti-Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 531-540. 10.35234/fumbd.738007.

Feng, H., Jiang, Z., Xie, F., Yang, P., Shi, J., & Chen, L. (2013). Automatic fastener classification and defect detection in vision-based railway inspection systems. *IEEE transactions on instrumentation and measurement*, 63(4), 877-888.

Liu, J., Huang, Y., Zou, Q., Tian, M., Wang, S., Zhao, X., & Ren, S. (2019). Learning visual similarity for inspecting defective railway fasteners. *IEEE Sensors Journal*, 19(16), 6844-6857.

Dou, Y., Huang, Y., Li, Q., & Luo, S. (2014). A Fast Template Matching-Based Algorithm for Railway Bolts Detection. *International Journal of Machine Learning and Cybernetics*, vol. 5, pp. 835-844.

Liu, J., Teng, Y., Ni, X., & Li, H. (2021). A Fastener Inspection Method Based on Defective Sample Generation and Deep Convolutional Neural Network. *IEEE Sensors Journal*, vol. 21, no. 10, pp. 12179-12188.

Özçelik, Y. B., & Altan, A. (2021). Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 156-167.