



## Ray Yüzey Kusurları ve Ray Kırıklarının Evrişimli Artık Ağ Modeli ile Sınıflandırılması

Murat BAŞARAN<sup>\*ID</sup>, Ömür AKBAYIR<sup>ID</sup>, Mehmet FİDAN<sup>ID</sup>, Mine SERTSÖZ<sup>ID</sup>, Muhammet ÖZTÜRK<sup>ID</sup>

*Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Raylı Sistemler Mühendisliği Anabilim Dalı, Eskişehir, Türkiye*

\*muratb@eskisehir.edu.tr

(Alınış/Received: 21.11.2022, Kabul/Accepted: 25.12.2023, Yayımlama/Published: 31.01.2024)

**Öz:** Demiryolu taşımacılığı, güvenilir, rekabetçi ve çevre dostu bir ulaşım ve yük taşıma alternatifi olduğu için günümüzde, demiryolu hatlarındaki trafiğin artması kaçınılmaz bir durumdur. Artan yolcu talebi sonucu sıklaşan seferler, tren hızlarının yükselmesi ve yüklerinin artması ile birleşince mevcut demiryolu üstyapısına önemli ek yükler getirmektedir. Bu ek yükler, raylarda olası problemlerin ortaya çıkma olasılığını arttırmaktadır. Buna bağlı olarak, raylarda görülen kusurlar daha önemli hale gelmiş; rayların kusurlara karşı kontrol edilmesi ve bakımının zamanında yapılması büyük önem kazanmıştır. Bu çalışmada ray görüntüleri Artık Ağ mimarisini kullanan evrişimli yapay sinir ağı ile eğitilmiş ve ray üzerindeki kusurlar ve ray kırıkları yüksek bir başarıyla sınıflandırılmıştır. Böylelikle birbirine karışma ihtimali fazla olan ve ayrıca ray kırığı probleminin öncülü olabilecek ciddi ray yüzey kusurlarının başlangıç aşamasında tespiti ile bakım onarım faaliyetlerine katkı sunabileceği düşünülmektedir.

**Anahtar kelimeler:** Demiryolu, Ray yüzey kusurları, Ray kırıkları, Derin öğrenme, Artık Ağlar

### Classification of Rail Surface Defects and Rail Cracks by Convolutional Residual Network Model

**Abstract:** Since railway transportation is a reliable, competitive, and environmentally friendly transportation and freight alternative, the traffic on railway lines will inevitably increase today. The increasing frequency of trips as a result of increasing passenger demand, combined with increased train speeds and increased loads, brings significant additional loads to the existing railway superstructure. These additional loads increase the likelihood of possible problems on the rails. Accordingly, the defects seen in the rails have become more important; It has become of great importance to check the rails for defects and to carry out their maintenance on time. In this work, rail images were trained with a convolutional artificial neural network using Residual Network architecture, and defects on the rail and rail cracks were classified with high success. Thus, it is thought that it can contribute to maintenance and repair activities by detecting serious rail surface defects at the initial stage, which are likely to interfere with each other and may also be the precursor of rail crack problems.

**Keywords:** Railway, Rail surface defects, Rail cracks, Deep learning, Residual Networks

## 1. Giriş

Rayların yüzeyindeki kusurlar, tespit edilip gerekli bakım faaliyeti uygulanmadığı takdirde raylı sistem taşıtlarının tekerlek takımlarında ve yataklarında büyük hasara neden olabilirler. Tekerlekler kusurlu yüzeylere sahip raylarda hareket ederken periyodik darbeler meydana getirecek ve bu darbeler tüm araçta ve raylarda birleşik bir temas titreşimine neden olacaktır. Döner temas yorgunluğu olarak adlandırılan ray tekerlek etkileşiminden kaynaklı bu olumsuzluk, uzun vadede demiryolu bileşenlerinin servis ömrünü kısaltır ve raylı sistem araçlarında raydan çıkmaya varacak önemli kaza risklerini doğurabilir. Bu nedenle raylardaki kusurların başlangıç aşamasında tespiti demiryolunun ve raylı sistem araçlarının daha güvenli ve verimli olarak kullanılarak demiryolu yük ve yolcu taşımacılığının güvenliğini sağlamak için önemli bir araçtır [1]. Yalnızca Avrupa Birliği ülkelerinde ultrasonik muayene ve takiben manuel doğrulama

Atıf için/Cite as: M. Başaran, Ö. Akbayır, M. Fidan, M. Sertsöz, M. Öztürk, "Ray yüzey kusurları ve ray kırıklarının evrişimli artık ağ modeli ile sınıflandırılması," *Demiryolu Mühendisliği*, no. 19, pp. 160-170, Jan. 2024. doi: 10.47072/demiryolu.1207956

süreçlerini de kapsayan demiryolu hat izleme ve kestirimci bakım faaliyetlerinin maliyetinin yıllık olarak yaklaşık olarak 70 milyon Euro olduğu hesaplanmaktadır [2]. Sadece olası kazalardan kaçınmak için değil, aynı zamanda araçların ve demiryolunun hizmet ömrünü uzatmak ve oluşacak muhtemel bakım maliyetlerini ve bakım onarım için harcanacak zamanın azaltılmasında kestirici bakım faaliyetleri ile alınacak önlemlerin önemi büyüktür ve demiryolu işletme maliyetlerini düşüreceği aşikardır [3].

Avrupa Birliği ülkelerinde olduğu gibi, ülkemizde de işletmedeki problemlerin erken aşamada tespit edilmesi, ray yüzey kusurlarının tespiti ve ray kırıklarının oluşmadan önce önlem faaliyetlerinin alınması büyük önem arz etmektedir. Ülkemizde Türkiye Cumhuriyeti Devlet Demiryolları (TCDD) eliyle yürütülen bu faaliyetlerin en önemlisi deneyimli teknik personel ile yapılan görsel muayenelerdir. Gözle kontrol ray yüzey kusurlarının tespitinde ve sınıflandırılmasında önemli bir muayene yöntemi olduğu için gerekli görsel muayeneyi yapan personelin demiryolu hat kontrolünde gerekli bilgi ve tecrübeye sahip olması gerekmektedir. Deneyimli personel, TCDD'nin yayınlamış olduğu 106 numaralı genel emir ile tanımlanan standartlarla ve sorumluluk çerçevesinde gerekli kontrolleri yaparlar. Bu genel emir çerçevesinde görsel muayene hızlı tren hatlarında 2 ayda bir, konvansiyonel hatlarda ise 6 ayda bir yapılmaktadır. Muayene esnasında tespit edilen kusurlar önem derecesine göre; küçük hatalar, büyük hatalar ve kritik hatalar olmak üzere 3 sınıfta toplanır ve raporlanır [4]. Günümüzde görsel veriler artan teknolojik imkanların yardımıyla gözle muayeneye destek olacak şekilde hızla gelişen görüntüleme teknolojilerini kullanan muayene treni ile de toplanabilmektedir. TCDD'ye ait Piri Reis muayene treni ile yüksek hızlı tren (YHT) hattının durumunu ve hat ile tren arasındaki etkileşimin takibi yapılabilmektedir. Görsel veriler, uyumlu bir aydınlatma sistemi ve doğrusal tarayıcı kamera tarafından toplanır. MERMEC şirketi tarafından üretilen VCUBE adı verilen gelişmiş bir makine görüş sistemi tarafından yakalanan ardışık görsellerden oluşan demiryolu hattının kamera görüntüleri, görsel muayeneye çok değerli katkılarda bulunmaktadır [5]. Şekil 1'de görseli verilen VCUBE makine görüş sistemi yardımı ile ray yüzeyindeki hatalarının yanı sıra ray mantarının profilini, aşınma miktarını, ekartman açıklığını, traverslerin konumunu, balast yeterliliğini ve bağlantı elemanlarının durumunu da izlemek mümkün olmaktadır. Muayene esnasında operasyon hızı 250 km/saate kadar ulaşabilmekte ve testler her 3 ayda bir periyodik olarak gerçekleştirilmektedir [6].



Şekil 1. MERMEC VCUBE makine görüş sistemi

Ray tekerlek etkileşimi ile oluşan en büyük problemlerden biri yorulma kaynaklı çatlaklardır. Kaynak bölgeleri rayların en problemleri bölgeleri olup buralarda da meydana gelen aşınmalar ve çatlakların erken tespiti çok önemlidir [7].

Ray kusurları, üretim kaynaklı veya kullanım kaynaklı olabilmektedir. Üretimden kaynaklı ray kusurları fitil kusurları, ham madde kusurları ve merdane kusurları olarak sıralanabilir [8].

Kullanım sonucu ray aşınması aks yükü, tren hızı, tekerlek ve ray profilleri, tekerlek ve rayın malzeme özellikleri, ray eğriliği, tekerlek ray temas yüzeyinin durumu, temas basıncı, yağlama ve çevresel diğer çevresel etkiler gibi çok çeşitli parametrelere bağlıdır [9]. Kullanım sonucunda oluşan ray kusurları ray mantarında oluşan sıralı kılcal çatlaklar, ezilmeler, kabuk atma, ondülasyon, periyodik yuvarlanma yüzeyi hasarları, zedelenme, patinaj izi ve diğer kılcal çatlak kusurlarıdır.

Ray mantarında sıralı kılcal çatlaklara genellikle tren gidiş yönünde, kurpların dış raylarının yuvarlanma yüzeyinde karşılaşılır ve temas yüzeyinde meydana gelen gerilmelerin bir sonucudur. Ezilmeler ise yuvarlanma temas bölgesinde yatay bir düzlemde uzanan bir temas çatlağıdır ve yuvarlanma yüzeyinde çökmelere yol açar. Kabuklanma genellikle kuplarda dış rayda görülen karakteristik bir yuvarlanma temas yorulma kusurudur. Oluş mekanizması ray yüzeyi yönünde mantarın içine doğru çatlakların ilerlemesi ve yuvarlanmanın yüzeylerde uzunlamasına, üretime bağlı kopmalara ve yuvarlanma yüzeyinde bölgesel çökmelere sebep olmasıyla gelişmektedir. Ondülasyon, ray yüzeyinin dalgalı bir biçimde aşınmasıdır. Ray yüzeyinin dalga boyları 20 ile 80 mm arasında ve neredeyse periyodik bir tekrarla bozulması durumu olarak görülür. Periyodik yuvarlanma temas yorulma kusurları ise yüksek hızlı tren hatlarında büyük dinamik kuvvetlerin ray yüzeyinde malzeme deformasyonuna neden olmasından kaynaklanmaktadır. Zedelenme kusuru ise teker ve ray arasına balast gibi yabancı maddelerin kaçması sonucu oluşmaktadır ve yuvarlanma yüzeyine yatay konumda, rasgele dağılmış halde karşılaşmaktadır. Trenin ani hızlanmaları ya da yavaşlamaları sonucu ray yüzeyinde çökmeler meydana gelebilir. Bu çöküntülere patinaj izi denir ve içerisinde çatlaklar barındırabilir. Sık karşılaşılan kılcal çatlaklar, önlem alınmadığı takdirde ileri aşamalarda ray kırıklarına sebep olabilir. Yukarıda sayılan ray kusurlarından seçilmiş örnek dört farklı ray kusuru görseli Şekil 2’de gösterilmiştir.




Şekil 2. Çeşitli ray yüzey kusuru örnekleri [10]

Bu çalışmada VCUBE makine görüş sistemi tarafından yakalanan demiryolu hattının yüksek çözünürlüklü görüntülerinden oluşan bir veri kümesinden yararlanıyoruz. VCUBE tarafından elde

edilen görüntüler, yazılım tarafından işlenmekte ve görüntü işleme teknikleri ile program hattın hangi kilometresinde hangi tip ray veya ray bağlantı elemanı kusuru olabileceğini içeren bir çıktı üretmektedir. Daha sonra yetkili uzman personel bu çıktıları inceleyerek yazılımın verdiği sonuçları teyit etmektedir. Bazı durumlarda özellikle ray yüzey kusuru tespitinde ray üzerine gelen kum, toprak, ağaç yaprakları, kuş pislikleri gibi bazı dış çevresel etmenler nedeniyle yazılım hatalı çıktılar üretilebilmektedir. Deneyimli uzman personel tarafından gerekli kontroller yapılmakta ve yazılımın çıktıları teyit veya reddedilerek nihai saha raporları oluşturulmaktadır.

Bu çalışmada önerilen yöntemin sağlıklı ve güvenilir sonuçlar vermesi adına VCUBE tarafından elde edilen görüntüler doğrudan kullanılmamış, bunun yerine Polatlı – Konya YHT hattı üzerinde uzman personel tarafından teyitli bir saha raporu üzerindeki gri tonlamalı resimler kullanılmıştır. Çalışmada ray kırığı (rail crack) ve ray yüzey kusuru (rail surface defect) olmak üzere iki sınıflı bir sınıflandırma problemi tanımlanmıştır. Bu iki sınıfa ait ikişer örnek gri tonlamalı resim ve hatalara ait detaylar Şekil 3'te görülmektedir. Söz konusu raporda toplam 60 adet ray kırığı olarak teyitli ve toplam 195 adet ray yüzey kusuru olarak teyitli görüntü bulunmaktadır. Çalışma, bu görüntüleri kullanan iki sınıflı bir sınıflandırma problemine çözüm metodu üretmektedir. Çalışmada demiryolu görsel muayene prosedürüne derin öğrenme tabanlı bir destek mekanizması üretilmeye çalışılmıştır.




Şekil 3. Çalışmada kullanılan saha raporundan iki sınıfa ait örnek resimler

## 2. Metot

Bu çalışmada gri tonlamalı ray görüntüleri aracılığı ile verilen görüntünün hangi sınıfa ait olduğunun derin öğrenme ağları yardımı ile sınıflandırılmasına yönelik bir yöntem önerilmiştir. Çalışmada iki sınıflı bir sınıflandırma problemi ortaya konmuştur. Veri setindeki görüntüler ray yüzey kusuruna (rail surface defect) ya da ray kırığı (rail crack) sahip gri tonlamalı jpg formatlı resimlerdir. Çalışmada Convolutional Neural Networks (CNNs) olarak bilinen yapay sinir ağları alanında önemli bir gelişme olan Evrişimli Sinir Ağlarının bir modeli olan Artık Ağlar: Residual Networks (ResNet) ile testler gerçekleştirilmiştir.


ResNet, derin öğrenme alanında önemli bir dönüm noktası olarak kabul edilir. İngilizce "residual" yani "artık" anlamına gelen ResNet, Microsoft Research tarafından geliştirilmiştir [11]. ResNet, kendinden önceki derin öğrenme modellerinin aksine, çok daha derin ağların eğitilmesini mümkün kılan bir yenilik getirir. ResNet'in temel fikri, ağın her katmanının, giriş verisini artık veya fark olarak değil, orijinal giriş verisini hedef çıkış verisine yaklaştırmak amacıyla ona bir kimlik fonksiyonu ekleyerek çalışır. Böylelikle Şekil 4'te gösterilen bir öğrenme bloğu oluşturulur.



Şekil 4. Artık öğrenme bloğu örneği

Derin öğrenme ağlarının derinleşmesi, genellikle derin ağ sorunu olarak adlandırılan bazı zorlukları beraberinde getirmektedir. Derin ağlar, girişten çıkışa kadar birçok katman içerir ve her katman öncekine göre daha soyut ve yüksek seviyeli özellikler öğrenmektedir. Ancak ağın daha derin hale gelmesi, geriye doğru eğitim sırasında gradyan kaybı sorununa neden olabilir. Bu, ağın ilk katmanlarına geriye doğru eğitim sırasında çok küçük gradyanların iletilmesi sonucu olur. Bu durum ağın eğitimini zorlaştırır. ResNet, bu sorunu aşmak için artık bağlantılar (residual connections) kullanmaktadır. Her katman, kendisine önceki katmandan gelen bir artık bağlantı ile birleştirilmektedir. Bu, giriş verisinin artık fonksiyonlar tarafından dönüştürülen çıkış verisi ile toplanmasını sağlar. Bu sayede, ağın her katmanı orijinal giriş verisine yakın bir çıkış üretebilir ve gradyan kaybı sorununu azaltır.

ResNet'in temel yapısı, ardışık olarak bir araya getirilmiş bir dizi artık blok (residual block) içermektedir. Her artık blok, artık bağlantılar içerir ve genellikle birkaç evrişim (konvolüsyon) katmanı, toplama katmanları (artık bağlantıları yönetir) ve aktivasyon fonksiyonlarını içerir. Bu bloklar, birçok derin katmandan oluşan büyük bir ağı daha rahat bir şekilde eğitilebilir hale getirir. Örnek olarak Şekil 5'te ResNet-18 mimarisinin yapısı verilmiştir.




Şekil 5. Örnek ResNet Mimarisi (ResNet-18)

ResNet, birçok avantaj sunmaktadır. Derin ağları eğitime yeteneği ile daha derin ve karmaşık ağların eğitimini mümkün kılar, bu da daha iyi performans ve daha yüksek doğruluk sağlar. Artık bağlantılar, gradyanların daha iyi iletilmesini sağlar ve geriye doğru eğitimi daha verimli hale getirir. ResNet, daha az parametre kullanarak daha derin ağlar oluşturmaya olanak tanır, bu da daha hızlı eğitim süreleri ve daha az bellek kullanımı gibi avantajlar sağlamaktadır.

ResNet veya diğer evrişimli sinir ağı (CNN) mimarilerini gri tonlamalı görüntü sınıflandırma görevlerine uygulamak mümkündür. Tipik olarak ResNet gibi modeller, her pikselin üç renk kanalı içerdiği RGB (Kırmızı, Yeşil, Mavi) renkli görüntüler üzerinde tasarlanır ve eğitilir. Ancak bu mimariler gri tonlamalı görüntüleri de işleyebilir. Gri tonlamalı görüntüler, üç renk kanalı yerine her pikselin yoğunluğunu temsil eden yalnızca bir kanal içerir. Gri tonlamalı görüntü sınıflandırması için önceden eğitilmiş bir ResNet modeli kullanırken gri tonlamalı görüntüleri sözde RGB'ye (pseudo RGB) dönüştürmek gerekmektedir. Gri tonlamalı değerleri üç kanalı

tamamında çoğaltarak tek kanallı (gri tonlamalı) görüntüleri üç kanallı (sözde RGB) görüntülere dönüştürmek mümkündür. Bu, gri tonlamalı piksel değerlerinin Kırmızı, Yeşil ve Mavi kanallara kopyalanması, esasen her üç kanalda da orijinal görüntünün gri tonlamalı versiyonunun oluşturulması anlamına gelir. Daha sonra bu sözde RGB görüntüleri sanki renkli görüntülemiş gibi ResNet modeline beslemek mümkün olmaktadır. Şekil 6'da bu çalışmada kullanılan veri setindeki örnek bir görüntünün üç kanallı sözde RGB görüntüye dönüştürüldükten sonraki hali verilmiştir.



Şekil 6. Veri setindeki ray görüntülerinden elde edilmiş sözde RGB resim örneği

Literatürde, demiryolu ray muayene ve kusur tespiti problemlerinde ResNet modellerini de içeren derin öğrenme metodlarının kullanıldığı makale sayısı giderek artmaktadır. 2020 yılında Çinli bir grup araştırmacı 41 katmanlı artık ağ kullanarak demiryolu yüzeyindeki kabuklanma problemini tespit etmeye çalışmışlardır. [12] Yine aynı yıl demiryolu ray bağlantı elemanlarında kusur teşhisi için Çekişmeli Üretici Ağ (Generative Adversarial Network- GAN) ve Resnet'in beraber kullanıldığı derin öğrenmeye dayalı bir yöntem önerilmiştir [13]. Yine benzer konuda 2021 yılında yapılan bir çalışmada ray bağlantı elemanlarında hata tespiti için kırık, kayıp ve sağlam olmak üzere üç sınıflı bir sınıflandırma problemi içeren bir çalışma yapılmış ve Spatial pyramid pooling (SPP) destekli ResNet ile %96'ya varan bir başarı oranı yakalanmıştır [14]. Ray kırıklarının tespitinde de derin öğrenmenin kullanıldığı çalışmalar mevcuttur. Yine 2021 yılında yapılan bir çalışmada ray yüzeyindeki çatlakların tespitine yönelik etkili veri odaklı modeller geliştirmek için derin öğrenme çerçevesi sunulmuş ve sunulan çerçevede ilk olarak topluluk öğrenmesine dayalı YOLOv3 modelini COCO veri seti üzerinde önceden eğitilmiş ağırlıklara sahip modeli kullanan ve daha sonra transfer öğrenimi yoluyla demiryolu hattındaki çatlakları tespit eden bir çalışma yapılmıştır [15]. YOLOv3 modelinin entegre edilmesinin ve arıza tespit başarısında olumlu etkisinin olduğu görülmüştür. Ülkemizde de topluluk öğrenmesine dayalı bir ray yüzey kusuru tespit problemi üzerinde çalışılmış ve farklı YOLO modelleri için topluluk öğrenmesine dayalı bir yöntem önerilmiştir [16]. Çalışmanın sonucunda 8 farklı kusur içeren veri seti üzerinde bütün sınıfları içeren tespit oranının %80'in üzerinde bir başarıya sahip olduğunu gösterilmiştir. Yine ülkemizde yapılan başka bir çalışma, ray kusur tespitinde ResNet-18, ResNet-50 ve ResNet-101 modellerini kullanmış ve yine %80 civarında başarılı sınıflandırma sonuçlarına ulaşmıştır [17]. Yine ülkemizde güncel konulardan biri olan açıklanabilir yapay zekâ temelli bir yaklaşım ile ray yüzey kusurları tespit edilmiştir. Söz konusu çalışmada Vgg16 ve MobileNetV3 modellerinin sınıflandırıcı katmanlarının özelleştirilmesiyle yapılan uygulamada, etiketsiz verilerle öğrenme ve ray yüzey kusurlarının açıklama haritaları ile tespitinde %98 e varan doğruluk oranı ile sınıflandırma başarısı elde edilmiştir [18]. Demiryolu bakım konuları içinde sadece ray kusurları değil farklı konularda da ResNet kullanılan makaleler literatürde mevcuttur. Örneğin katener sistemlerindeki izolatör kusurlarının derin öğrenme ile tespiti ile ilgili bir çalışmada ResNet-34 mimarisi kullanılmış ve 1100 adet izolatör görüntüsü içeren veri seti ile %95'in üzerinde bir sınıflandırma başarısı elde edilmiştir [19].

### 3. Bulgular

Bu çalışmada VCUBE makine görüş sistemi tarafından Polatlı – Konya YHT hattı üzerinde elde edilen görüntülerden uzman personel tarafından oluşturulmuş teyitli bir saha raporu üzerindeki gri tonlamalı resimler kullanılmıştır. Çalışmada ray kırığı (rail crack) ve ray yüzey kusuru (rail surface defect) olmak üzere iki sınıflı bir sınıflandırma problemi tanımlanmıştır. Söz konusu raporda toplam 60 adet ray kırığı olarak teyitli ve toplam 195 adet ray yüzey kusuru olarak teyitli görüntü bulunmaktadır. Bu gri tonlamalı resimlerin tamamı eğitim ve test verisinde kullanılmaktadır, başka görüntü işleme tekniği kullanılarak veri artışı yapılmamıştır. Veriler önceden eğitilmiş bir evrişimli yapay sinir ağı modeli olan artık ağ (residual network, ResNet) ile sınıflandırılmıştır.

ResNet, ImageNet veri tabanının bir alt kümesi üzerinde eğitilmiş ve 2015 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) yarışmasını kazanmış, önceden eğitilmiş bir modeldir. Model, bir milyondan fazla görüntü üzerinde eğitilmiştir ve görüntüleri farklı 1000 nesne kategorisine sınıflandırabilir. Deneysel çalışmada literatürde çok sayıda farklı varyasyonları bulunan ResNet mimarilerinden üç tanesi kullanılmıştır. Bunlar, önceden eğitilmiş ResNet-18, ResNet-50 ve ResNet101 mimarileridir. Bu ağların mimarisi sırasıyla 18 (72 alt katman), 50 (177 alt katman) ve 101 (347 alt katman) katmandan oluşmaktadır.

Deneysel çalışmanın veri setindeki görüntüler 60 adeti ray kırığı ve 195 adeti ray yüzey kusuru olarak teyitli olmak üzere toplamda 255 adettir. Bu iki sınıftaki görüntülerin %70'i sistemi eğitmek için (train set) kalan %30'u da eğitim sonrası sistemin performansını test etmek için (test set) rasgele olarak ayrılmıştır. Kullanılan üç farklı ResNet mimarisinin sınıflandırma başarısı, karışıklık matrisleri (confusion matrix) aracılığı ile görselleştirilmiştir.

Karışıklık matrisi, makine öğreniminde bir sınıflandırma modelinin doğruluğunu temsil eden bir performans değerlendirme aracıdır. Gerçek pozitiflerin, gerçek negatiflerin, yanlış pozitiflerin ve yanlış negatiflerin sayısını görüntüler. Bu matris, model performansının analiz edilmesine, yanlış sınıflandırmaların belirlenmesine ve tahmin doğruluğunun iyileştirilmesine yardımcı olur.

Karışıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan, N sınıf sayısı olmak üzere, N x N boyutlu bir matrisidir. Matris, gerçek hedef değerlerini makine öğrenimi modelinin tahmin ettiği değerlerle karşılaştırır. Bu bize sınıflandırma modelimizin ne kadar iyi performans gösterdiğine ve ne tür hatalar yaptığını dair bütünsel bir görünüm sağlar. Bu çalışmada olduğu gibi ikili bir sınıflandırma problemi için, aşağıda gösterildiği gibi 4 değere sahip 2 x 2'lik bir karışıklık matrisi oluşur:

		Gerçek değer	
		Pozitif	Negatif
Tahmin	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 7. 2 x 2'lik karışıklık matrisi

Bu değerler TP, FP, FN ve TN dir. Eğer tahmin işleminde normalde pozitif olarak var olan bir durum pozitif olarak tahmin ediliyorsa TP (true positive) bir tahmin yapılmıştır. Eğer var olan durum negatif ve tahmin negatif ise TN (true negative) bir tahmin yapılmıştır. Başka bir deyişle yanlış bir durum yanlış olarak doğru bir şekilde tahmin edilmiştir. Eğer var olan durum negatif ise ancak tahmin sistemi pozitif olarak tahmin ederse birinci tip hata FP (false positive) durumu oluşur. Eğer var olan durum pozitif ise ve tahminci negatif olarak tahmin ederse FN (false negative) ikinci tip hata oluşur.

Karışıklık matrisi üzerinden çıkarılan literatürde sıklıkla kullanılan performans metrikleri ile sistemin sınıflandırma başarı performansı ölçülebilir. Bu metrikler sırasıyla doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F-skoru (F-score) dur.

Doğruluk, sistemde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır.

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

Duyarlılık, pozitif durumların ne kadar başarılı tahmin edildiğini gösterir.

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

Kesinlik, pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren durumdur.

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

F-skoru, duyarlılık ve kesinliğin harmonik ortalamasıdır.

$$F = 2 \times \frac{\text{duyarlılık} \times \text{kesinlik}}{\text{duyarlılık} + \text{kesinlik}} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4)$$

ResNet-18 ile test sonucunda oluşan karışıklık matrisi:

Tahmin	Gerçek değer	
	Ray kırığı (rc)	Yüzey kusuru (sd)
Ray kırığı (rc)	17	1
Yüzey kusuru (sd)	0	58

Şekil 8. ResNet-18 ile test sonucu oluşan karışıklık matrisi

ResNet-50 ile test sonucunda oluşan karışıklık matrisi:

Tahmin	Gerçek değer	
	Ray kırığı (rc)	Yüzey kusuru (sd)
Ray kırığı (rc)	18	0
Yüzey kusuru (sd)	1	57

Şekil 9. ResNet-50 ile test sonucu oluşan karışıklık matrisi

ResNet-101 ile test sonucunda oluşan karışıklık matrisi:

Tahmin	Gerçek değer	
	Ray kırığı (rc)	Yüzey kusur (sd)
Ray kırığı (rc)	18	0
Yüzey kusuru (sd)	0	58

Şekil 10. ResNet-101 ile test sonucu oluşan karışıklık matrisi

Elde edilen bu sonuçlara göre sınıflandırma performans metrikleri ise şu şekilde oluşmaktadır:



**Tablo 1.** Önerilen ResNet mimarilerine göre sistemin performans metrikleri

	ResNet-18	ResNet-50	ResNet-101
Doğruluk	0,9868	0,9868	1,0000
Duyarlılık	1,0000	0,9473	1,0000
Kesinlik	0,9444	1,0000	1,0000
F-skoru	0,9444	0,9473	1,0000

Karışıklık matrisleri ve performans metrikleri incelendiğinde, en iyi sınıflandırma başarısının ResNet-101 ağı ile eğitilen durumda gerçekleştiği görülmektedir. ResNet-101 ile %100 başarılı sınıflandırma gerçekleştirilirken diğer iki mimaride de %98'in üzerinde bir sınıflandırma başarısına ulaşılmıştır.

#### 4. Sonuç

Bu çalışmada ray yüzey kusuru ve ray kırığı sınıflandırma problemi günümüzde pek çok alanda öncü yenilikler getiren derin öğrenme yöntemlerinden olan artık ağ yaklaşımı ile çözülmeye çalışılmıştır. Önerilen üç farklı artık ağ mimarisi de oldukça yüksek sınıflandırma başarısı göstermiştir. Sınıflandırma başarısı daha fazla katman barındıran ResNet-101 modeline %100'e kadar çıkmış, diğer iki mimaride de %98'in üzerinde bir başarılı sınıflandırma gerçekleştirilmiştir. Raylı sistem işletmeciliğinin güvenliği ve güvenilirliği için kestirimci bakım faaliyetlerinin olmazsa olmazı olan görsel muayene süreçlerinde uzman personelin karar verme mekanizmasında derin öğrenme metotları ile yapılan hata sınıflandırma işlemleri büyük avantajları beraberinde getirmektedir. Hem uzman personelin nihai kararı vermesine yardımcı olduğu gibi hem de karar verme süreçlerini hızlandırarak eğer gerekiyorsa ilgili bakım onarım faaliyetinin bir an önce gerçekleştirilebilmesi için zaman kazandırmaktadır. Bu çalışma birbirine karışma ihtimali fazla olan ve ayrıca ray kırığı probleminin öncülü olabilecek ciddi ray yüzey kusurlarının başlangıç aşamasında tespiti ve doğru sınıflandırıldığı düşünüldüğünde bakım onarım faaliyetlerine ciddi katkı sunabileceği muhakkaktır. Dahası, bu çalışma farklı ray hata tiplerini sınıflandıracak ve ayrıca ray bağlantı elemanlarında oluşabilecek deformasyon ve kayıpları da tespit edecek şekilde genişletilebilecek niteliktedir.

#### Teşekkür

Bu çalışma Eskişehir Teknik Üniversitesi Bilimsel Araştırma Projeleri tarafından 22ADP036 no'lu proje ile desteklenmiştir. TCDD Demiryolu Araştırma ve Teknoloji Merkezi İşletme Müdürlüğü (DATEM)'ne teşekkür ederiz.

#### Kaynakça

- [1] L. Kou, "A review of research on detection and evaluation of the rail surface defects.", *Acta Polytech. Hungarica* vol. 19 no. 3, pp. 167-186, 2022.
- [2] Z. Popović, V. Radović, L. Lazarević, V. Vukadinović, & G. Tepić, "Rail inspection of RCF defects.", *Metalurgija*, vol. 52 no. 4, pp. 537-540, 2013.
- [3] A. Falamarzi, S. Moridpour, & M. Nazem, "A review on existing sensors and devices for inspecting railway infrastructure.", *Jurnal Kejuruteraan*, vol. 31 no.1, pp. 1-10, 2019.
- [4] "Rayların Gözle Muayenesine Ait 106 No'lu Genel Emir", TCDD 106 Nolu Genel Emir, 2012.
- [5] V. W. Anelli *et al.*, "Deep learning-based adaptive image compression system for a real-world scenario." *2020 IEEE Conference on Evolving and Adaptive Intelligent Systems (EAIS)*, 2020.
- [6] "Piri Reis Yüksek Hızlı Test Treni Raporu", TCDD, Ankara, 2017.
- [7] M.A. Sevim, A.C. Çelt, S. Kabar, and Ö. Akgünlü "Demiryollarında raylara uygulanan tahribatsız muayene yöntemleri," *Demiryolu Mühendisliği*, no. 11, pp. 60-74, Jan. 2020.

- [8] A. Çelik, "Demiryolu ray ve kusurlarını tespit etmek için geliştirilen iki yeni yöntem," *Demiryolu Mühendisliği*, no. 12, pp. 52-63, July. 2020. doi: 10.47072/demiryolu.737624
- [9] H. Yılmaz Sönmez, & Z. Öztürk, "Effects of traffic loads and track parameters on rail wear: A case study for Yenikapı–Ataturk Airport Light Rail Transit Line." *Urban Rail Transit*, vol. 6 no. 4, pp. 244-264, 2020.
- [10] "Rail Defects Handbook: Some Rail Defects, their Characteristics, Causes and Control", RC 2400 Issue A, Revision 0, Australian Rail Track Corporation, 2006.
- [11] K. He, *et al.*, "Deep residual learning for image recognition.", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [12] X. Song, K. Chen, & Z. Cao, "ResNet-based image classification of railway shelling defect.", *Proceedings of 39<sup>th</sup> Chinese Control Conference* pp. 6589-6593, 2020.
- [13] D. Yao, Q. Sun, J. Yang, H. Liu, & J. Zhang, "Railway fastener fault diagnosis based on generative adversarial network and residual network model.", *Shock and vibration*, pp.1-15, 2020.
- [14] D. Wang, H. Su, G. Chen, D. Xu, L. Wang, & X. Zhao, "Defect Detection Method of Railway Fastener Based on SPP-improved ResNet", *IEE CAA Symposium on Fault Detection, Supervision, and Safety for Technical Processes (SAFEPROCESS)*, 2021.
- [15] Z. Zheng, H. Qi, L. Zhuang, & Z. Zhang, "Automated rail surface crack analytics using deep data-driven models and transfer learning.", *Sustainable Cities and Society*, no. 70, 2021.
- [16] M. Sevi, İ. Aydın, E. Akın, "Detection of rail surface defects based on ensemble learning of YOLOv5," *Demiryolu Mühendisliği*, no. 17, pp. 115-132, Jan. 2023. doi: 10.47072/demiryolu.1205483
- [17] M. Sarıtaş, Y.S. Taşpınar, İ. Çınar & M. Köklü, "Railway Track Fault Detection with ResNet Deep Learning Models.", *International Conference on Intelligent Systems and New Applications (ICISNA'23)*, pp. 66-72, 2023.
- [18] S.S. Kırat, İ. Aydın, "Açıklanabilir yapay zekâ tabanlı denetimsiz öğrenme ile ray kusur tespiti," *Demiryolu Mühendisliği*, no. 18, pp. 1-13, July 2023. doi: 10.47072/demiryolu.1231751
- [19] G. Karaduman, E. Akın, B. Binay, M. Dilekli, "Katener sistemlerindeki izolator kusurlarının derin öğrenme ile tespiti," *Demiryolu Mühendisliği*, no. 16, pp. 185-195, July. 2022. doi: 10.47072/demiryolu.1114665

## Özgeçmiş



### Murat BAŞARAN

Lisans eğitimini Eskişehir Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde 2005 yılında tamamlamıştır. Yüksek lisans ve doktora eğitimlerini Anadolu Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde sırasıyla 2009 ve 2016 yıllarında tamamlamıştır. Eskişehir Teknik Üniversitesi Ulaştırma Meslek Yüksek Okulu Motorlu Araçlar ve Ulaştırma Teknolojileri bölümünde Dr. Öğr. Üyesi olarak çalışmaktadır.

E-Posta: muratb@eskisehir.edu.tr



### Ömür AKBAYIR


Lise eğitimini Demiryolu Meslek Lisesinde, lisans ve yüksek lisans eğitimini Eskişehir Osmangazi Üniversitesi'nde, doktora eğitimini Gazi Üniversitesi'nde tamamlamıştır. 1999-2015 yıllarında TCDD'de Teknisyen ve Mühendis olarak, 2015-2018 yıllarında Anadolu Üniversitesi'nde Dr. Öğr. Üyesi olarak çalışmıştır. 2018 yılından bu yana Eskişehir Teknik Üniversitesi'nde çalışmakta olup Doç. Dr. unvanını 2022 yılında almıştır.

E-Posta: omurakbayir@eskisehir.edu.tr

**Mehmet FİDAN**

Eskişehir Osmangazi Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. Yüksek lisans ve doktora eğitimini Anadolu Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde tamamladı. Eskişehir Teknik Üniversitesi, Ulaştırma Meslek Yüksek Okulu Raylı Sistemler Elektrik-Elektronik Programında doktor öğretim üyesi olarak çalışmakta ve yine aynı alanda akademik çalışmalarına devam etmektedir.

E-Posta: mfidan@eskisehir.edu.tr

**Mine SERTSÖZ**

1984 tarihinde Bilecik'in Pazaryeri ilçesinde doğdu. Yıldız Teknik Üniversitesi Elektrik Mühendisliğinden mezun oldu. Yüksek Lisansını Kocaeli Üniversitesi Elektrik Mühendisliği bölümünde, Doktora eğitimini ise Bilecik Şeyh Edebali Üniversitesi Enerji Sistemleri Mühendisliği bölümünde tamamladı. Eskişehir Teknik Üniversitesi, Ulaştırma Meslek Yüksek Okulu Raylı Sistemler Elektrik Bölümünde öğretim görevlisi olarak çalışmakta ve yine aynı alanda akademik çalışmalarına devam etmektedir. Evli ve iki çocuk annesidir.

E-Posta: msertsoz@eskisehir.edu.tr

**Muhammet ÖZTÜRK**

Lisans eğitimini Tekirdağ Namık Kemal Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümünde 2018 yılında tamamlamıştır. Halen Eskişehir Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Raylı Sistemler Mühendisliği Anabilim Dalında yüksek lisans eğitimine devam etmektedir.

E-Posta: muhammet.8494@gmail.com

**Beyanlar:**

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Yazarların katkıları: Murat BAŞARAN: Kavramsallaştırma, Metodoloji, Yazma-gözden geçirme ve düzenleme, Yazılım. Ömür AKBAYIR: Verilerin temini, Sonuçların yorumlanması. Mehmet FİDAN: Yazma-gözden geçirme ve düzenleme. Mine SERTSÖZ: Yazma-gözden geçirme ve düzenleme. Muhammet ÖZTÜRK: Görselleştirme, Taslak hazırlama.