

**Bulanık Modelleme ve CNN-BILSTM Ağı Kullanılarak Ray Yüzeyi Kusurlarının Tespiti ve Sınıflandırılması için Kararlı İki Aşamalı Yaklaşım**İlhan AYDIN^{*1}, Mehmet SEVİ², Erhan AKIN¹¹ Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elâzığ, Türkiye² Muş Alparslan Üniversitesi, Bilgi İşlem Daire Başkanlığı, Muş, Türkiye

*m.sevi@alparslan.edu.tr

(Alınış/Received: 14.06.2025, Kabul/Accepted: 23.07.2025, Yayınlama/Published: 31.07.2025)

Öz: Ray yüzeyindeki kusurlar, demiryolu taşımacılığını olumsuz etkileyen önemli bir sorun teşkil etmektedir. Bu tür kusurların zamanında tespit edilmesi, hat üzerindeki tehlikelerin belirlenmesi ve erken bakımın sağlanması sayesinde ciddi kazaların önlenmesine olanak tanır. Ancak, yüzeydeki pas ve yağ gibi safsızlıklar nedeniyle kusurların doğru şekilde tespit edilmesi oldukça zordur. Yüzey kusurlarının tespitinde temel amaç, yüksek doğruluk elde ederek gerçek kusurlar ile yalancı alarmların karıştırılmasını engellemektir. Bu çalışmada, söz konusu zorlukların üstesinden gelmek amacıyla iki aşamalı, hızlı bir ray yüzeyi kusur tespit yöntemi önerilmektedir. İlk olarak, demiryolu görüntüsünde rayları içeren piksellerin farklılıkları analiz edilerek ray çıkarımı gerçekleştirilir. Daha sonra, ön işleme adımında oluşabilecek gürültüler giderildikten sonra, sağlam bir ray görüntüsünün histogramı bulanık üyelik fonksiyonu kullanılarak modellenir. Kusurlu ray, bu bulanık üyelik değerlerine göre bölütlenir ve kusur olup olmadığı belirlenir. Kusur türünün sınıflandırılmasında ise Evrişimsel Sinir Ağı- Çift Yönlü Uzun Kısa Süreli Bellek (CNN-BILSTM) yöntemi kullanılır. Önerilen yüzey kusur tespit yöntemi, iki farklı kıyaslama veri kümesinde (Rail Surface Defect Datasets - RSDD-I/II) mevcut yöntemlerden daha yüksek performans göstermiştir. Ayrıca, kusur türünü belirlemede %98,00 oranında tanıma başarısı elde edilmiştir.

Anahtar kelimeler: Demiryolu, Görüntü Segmentasyonu, Bulanık Ölçüm, Evrişimsel Sinir Ağları, Yüzey Kusurları, Kusur Tespiti.

A Stable Two-Stage Approach for Detection and Classification of Rail Surface Defects Using Fuzzy Modeling and CNN-BILSTM Network

Abstract: Surface defects on railway tracks pose a significant challenge that adversely affects railway transportation. Timely detection of such defects enables the identification of potential hazards on the track and facilitates early maintenance, thereby preventing serious accidents. However, accurate detection of these defects is quite difficult due to surface impurities such as rust and oil. The primary objective in detecting surface defects is to achieve high accuracy to prevent confusion between actual defects and false alarms. In this study, a fast, two-stage method for detecting rail surface defects is proposed to address these challenges. First, rail extraction is performed by analyzing the differences in pixels containing rails in railway images. Then, after eliminating noise that may occur during the preprocessing step, the histogram of a sound rail image is modeled using a fuzzy membership function. The defective rail is segmented based on these fuzzy membership values to determine the presence of a defect. For the classification of defect types, a Convolutional Neural Network–Bidirectional Long Short-Term Memory (CNN-BILSTM) method is employed. The proposed surface defect detection method has demonstrated superior performance compared to existing methods on two benchmark datasets (Rail Surface Defect Datasets – RSDD-I/II). Furthermore, a classification accuracy of 98.00% was achieved in identifying defect types.

Keywords: Railway, Image Segmentation, Fuzzy Measure, Convolutional Neural Networks, Surface Defects, Defect Detection

Atıf için/Cite as: İ. Aydın, M. Sevi, E. Akın, “Bulanık modelleme ve CNN-BILSTM ağı kullanılarak ray yüzeyi kusurlarının tespiti ve sınıflandırılması için kararlı iki aşamalı yaklaşım,” *Demiryolu Mühendisliği*, sy. 22, ss. 58-75, Temmuz 2025. doi: 10.47072/demiryolu.1719591

1. Giriş

Raylar, demiryolu sistemlerinde ulaşım güvenliğini sağlamak açısından kritik bileşenlerdir. Demiryolu taşımacılığı sistemlerinde yüksek hızlı tren hatlarının inşası ve kullanımının artması, vagonların ray yüzeyinde oluşturduğu gerilme, zorlu çalışma koşulları ve yoğun kullanım gibi etkenler, raylarda kusur oluşma olasılığını artırmaktadır [1]. Bu kusurların erken aşamada tespit edilememesi durumunda, zamanla ilerleyerek ciddi kazalara yol açabilmektedir [2]. Bu nedenle, demiryolu hatlarının periyodik olarak denetlenmesi ve bakımlarının yapılması, daha büyük kusurların oluşmasının önlenmesi açısından büyük önem taşımaktadır.

Raylarda meydana gelen kusurlar; Göçme (squattening), ezilme (crushing), dalgacık oluşumu (corrugation), ardışık raylar arasındaki boşluklar (gaps) ve ray çatlakları (rail cracks) gibi gruplarda sınıflandırılabilir [3]. Geleneksel, insan tabanlı kontrol sistemleri, deneyime dayalı olmaları, yavaş işlemleri ve hata yapma olasılıklarının yüksek olması nedeniyle ray kusurlarının tespitinde pratik değildir [4]. Ayrıca, ray denetimleri genellikle gece saatlerinde gerçekleştirildiğinden, personel güvenliği ve düşük görüş koşulları yanlış tespitlere yol açabilmektedir. Sensör tabanlı yöntemler; ultrasonik dalgalar [5], eddy current (foucault akımı) [6] ve lazer teknolojileri [7] gibi teknikleri kullanmaktadır. Ancak bu yöntemler, yüksek sensör güvenilirliği gerektirmesi ve sahada uygulanmalarının zorluğu gibi dezavantajlara sahiptir. Bu nedenle, otomatik olarak çalışabilen hızlı ve güvenilir ray kusur tespit sistemlerinin geliştirilmesi gereklidir.

Görsel tabanlı teknikler, ray bileşenlerindeki kusurların tespitine yönelik temassız denetim yöntemleri arasında önemli bir yer tutmakta olup, son yıllarda araştırmacılar tarafından giderek daha fazla kullanılmaktadır [8]. Zhuang ve ark. [1], sağlıklı ve kusurlu rayların ayırt edilmesi ve kusur türünün tanınması amacıyla kademeli bir derin öğrenme yöntemi önermiştir. Bu yöntem, kusur sınıflandırması için derin evrimsel sinir ağı ile görüntü işleme tabanlı özellikleri birleştirmektedir. Ray yüzeyindeki kusurlar, demiryolu sistemlerinin kalite ve güvenliğini ciddi şekilde tehdit etmektedir. Ancak, ray kusurlarının çeşitli ve rastlantısal yapısı nedeniyle, bu tür yüzey kusurlarının tespiti oldukça zorlu bir süreçtir.

Wang ve ark. [9], ray kusurlarını tespit etmek amacıyla Mask-RCNN tabanlı yeni bir yüzey kusur tespit ağı önermiştir. Bu ağ, çok ölçekli füzyon için tasarlanmış yeni bir özellik piramidi ile yapılandırılmıştır. Deneysel değerlendirme sonuçları, önerilen modelin oluşturulan veri kümesinde ortalama doğruluk (mAP) oranı olarak %98,70'e ulaştığını ve kusurların konumlarını daha hassas şekilde belirleyebildiğini göstermektedir. Başka bir çalışmada, Gan ve ark. [10], ön bilgiye ihtiyaç duymadan arka plan modelleme yoluyla ray yüzeyi kusurlarını tespit edebilen arka plan odaklı bir kusur tespit yöntemi önermiştir.

Yang ve ark. [2], ray yüzeyi kusurlarını tespit etmek için segmentasyon ve sinir ağı tabanlı bir yaklaşım geliştirmiştir; bu çalışmada dört farklı kusur türü tanımlanmıştır. Önerilen model, segmentasyon doğruluğunu artırmak amacıyla tam bağlantılı katmanı ortadan kaldırmıştır. Ayrıca, ray yüzeyi kusurlarını hassas şekilde bölütlemek amacıyla Gauss karışım modeli ve eğrilik filtresi tabanlı bir yöntem sunulmuştur [11]. Bu yöntemde, görüntü ön işleme ve ray yüzey alanının çıkarılmasının ardından, komşu pikseller Gauss yöntemi ile modellenmiştir.

Zhang ve ark. [12], az örnek içeren veri kümelerinde ray yüzeyi kusurlarını tespit etmek için CNN ve LSTM tabanlı bir yöntem önermiştir. Bu yaklaşım, ardışık piksellerin satır düzeyinde etiketlenmesini ve segmentasyon sırasında kusurlu satırların tamamının bölütlenmesini içermektedir. Her ne kadar bu yöntem az örnekli durumlarda etkili sonuçlar sunsa da, kusurun boyutunu belirleyememekte ve türünü tanıyamamaktadır. Bu sınırlamaları aşmak amacıyla, yakın zamanda yapılan bir çalışmada koşullu rastgele alanlar (CRF) ile evrimsel sinir ağlarının birleştirildiği bir yaklaşım önerilmiştir [13]. Önerilen çift yönlü evrimsel sinir ağı modeli, biri

anlamsal anlamı yakalamaya, diğeri ise küçük kusurları tespit etmeye yönelik iki bölümden oluşmaktadır. CRF yöntemi ile CNN'in birleşimi sayesinde kusurlar daha hassas bir şekilde analiz edilebilmektedir.

Wu ve ark. [14], ray yüzeyi kusurlarını tespit etmek için segmentasyona dayalı hibrit bir derin öğrenme yöntemi geliştirmiştir. Bu yöntemde, belirginlik (saliency) tahmini için ray sınırlarını tanımlayan bir kılavuz ağ oluşturulmakta, ardından klasik görüntü işleme teknikleri ile kusurlar tespit edilmektedir. Yang ve ark. [15], karmaşık ortamlarda ray yüzeyi kusurlarını tespit etmek için derin öğrenme ve makine görüşü tabanlı bir yaklaşım sunmuştur. Bu çalışmada, ray tespiti için kenar piksellerinin standart sapması kullanılmakta, ardından Grabcut segmentasyonu ile kusur bölütlemesi yapılmakta ve tespit edilen kusurlar YOLOv2 algoritması ile konumlandırılmaktadır.

Ray yüzeyindeki farklı kusurların doğru şekilde tespit edilebilmesi için topluluk öğrenmesine dayalı bir nesne tespit yaklaşımı önerilmiştir [16]. Bu yaklaşım, tespit performansını artırmak amacıyla çok omurgalı (multi-vertebrate) bir topluluk yöntemi kullanmaktadır. Aydın ve Akın [17], ray yüzeyi kusurlarını tanıma yönelik iki aşamalı bir yöntem önermiştir. Bu yöntemde, kusur tespiti için görüntü işleme ve bulanık mantık sistemleri, kusur türünün belirlenmesi için ise transfer öğrenme kullanılmıştır. Başka bir çalışmada, Tu ve ark. [18], ray bağlantı elemanları ve ray yüzeyine ilişkin kusurları tespit etmek için derin öğrenme tabanlı bir yöntem geliştirmiştir. Bu çalışmada, ray ve bağlantı elemanlarının tespiti için YOLACT tabanlı bir segmentasyon algoritması kullanılmakta, segmentasyonu yapılan ray yüzeylerinde kusur tespit edilirse, kusur türünü belirlemek için Mobilenetv2 yöntemi devreye sokulmaktadır. Aydın ve ark. [19] ise, Mobilenetv2 ve SqueezeNet derin sinir ağı modellerinden elde edilen özellikleri birleştirerek, bu özellikleri destek vektör makineleri (SVM) ile sınıflandırmış ve ray yüzeyindeki dört farklı kusur türünü ayırt edebilen bir veri kümesi oluşturmuştur.


Birçok çalışma, ray yüzeyinde kusur olup olmadığını yalnızca görüntü segmentasyonu tabanlı yaklaşımlar kullanarak analiz etmiş; ancak kusur türünü incelememiştir. Diğer bazı çalışmalar ise kusur türünü belirlemek amacıyla derin öğrenme tabanlı sınıflandırma yaklaşımları önermiştir. Bu çalışma ise hem tespit hem de sınıflandırma görevlerini iki aşamalı bir yaklaşımla ele almaktadır. İlk olarak, ray görüntüsünden ray yüzeyi bölgesi çıkarılmaktadır. Ardından, ön işleme aşamasında kusurların belirginleştirilmesi için bulanık üyelik modellemesi kullanılarak yüzeyde kusur olup olmadığı tespit edilmektedir. Eğer kusur tespit edilirse, geliştirilen CNN-BILSTM yaklaşımı aracılığıyla kusurun türü belirlenmektedir. Önerilen çalışmanın katkıları aşağıda sunulmaktadır:

- Ray çıkarımı, kusur segmentasyonu ve kusur türü tanıma işlemlerini otomatikleştirmek amacıyla sağlam bir ray yüzeyi kusur tespit algoritması önerilmiştir.
- Önerilen bulanık modelleme tabanlı kusur tespit yaklaşımında, yalnızca tek bir sağlıklı ray yüzeyi görüntüsü kullanılarak elde edilen model ile kusurlu raylar başarılı bir şekilde bölütlenmektedir.
- Görüntü ön işleme ve bulanık modellemenin birleştirilmesiyle, gri seviye görüntülerde piksellerin kusurlu bir duruma ait olup olmadığı öngörülebilmektedir.
- Önerilen yaklaşım, düşük çözünürlüklü görüntülerde birçok farklı kusur türünü yüksek doğrulukla tespit edebilmektedir.
- Kusur türü belirlendikten sonra, geliştirilen CNN-BILSTM yaklaşımı ile doğru bir şekilde sınıflandırılmaktadır.

Çalışmanın yapısı şu şekildedir: Bölüm 2, önerilen iki aşamalı yaklaşıma ilişkin ayrıntılı bir giriş sunmaktadır. Bölüm 3'te, demiryolu raylarındaki kusurların tespiti ve tanınmasına yönelik deneysel sonuçlar ele alınmaktadır. Sonuçlara ise Bölüm 4'te yer verilmektedir.

2. Metot

Önerilen sistem iki ana aşamadan oluşmaktadır. İlk aşamada ray tespiti yapılmakta, ardından ön işleme ve bulanık modelleme tabanlı kusur segmentasyonu gerçekleştirilmektedir. İlk adımda bir kusur tespit edilirse, kusur türünün belirlenmesi için CNN-BILSTM modeli kullanılmaktadır. Önerilen sistemin blok diyagramı Şekil 1’de sunulmuştur. Sistem, görüntü toplama, ön işleme, bulanık modelleme ile kusur tespiti ve CNN-BILSTM tabanlı sınıflandırma aşamalarını kapsamaktadır.



Şekil 1. Önerilen iki aşamalı ray yüzeyi kusur tespit ve sınıflandırma sistemine ait blok diyagram

Şekil 1’de gösterilen blok diyagramda, görüntüler uygun aydınlatma koşulları altında yüksek hızlı bir kamera kullanılarak ölçüm treni üzerinden elde edilmekte ve bir bilgisayarda depolanmaktadır. Oluşturulan veri setinde, görüntü ön işleme işleminin ardından ray çıkarımı gerçekleştirilmektedir. Elde edilen ray görüntüsünde, bulanık modelleme yöntemi kullanılarak kusur bölgeleri bölütlenmektedir. Eğer kusur tespit edilirse, önerilen evrişimsel sinir ağı modeli kusur türünün sınıflandırılması için kullanılmaktadır.

2.1. Görüntü ön işleme ve ray çıkarımı

Ölçüm treninden görüntü alınırken genellikle bir aydınlatma sistemi kullanılmasına rağmen, çevresel koşullar ve gün ışığı etkileri nedeniyle görüntülerde hâlen gürültü bulunabilir. Bu nedenle, belirli türdeki gürültüleri gidermek amacıyla bir görüntü ön işleme aşaması gereklidir. Önerilen yöntemde, ray desenini güçlendirmek ve ray hattını çıkarmak için 2 boyutlu (2D) Gabor filtresi kullanılmıştır. Gabor filtresi, görüntüyü filtrelemek için (1)-(4) numaralı denklemlerde verilen filtreyi uygulamıştır.


$$G(x, y) = \exp \left(-\frac{1}{2} \left(\frac{x_{\theta}^2}{\sigma_x^2} + \frac{y_{\theta}^2}{\sigma_y^2} \right) \right) \cos \left(\frac{2\pi x_{\theta}}{\lambda} + \Psi \right) \quad (1)$$

$$x_{\theta} = x \cos(\theta) - y \sin(\theta) \quad (2)$$

$$y_{\theta} = x \sin(\theta) + y \cos(\theta) \quad (3)$$

$$\sigma_x = \sigma, \sigma_y = \sigma/\gamma \quad (4)$$

(1) numaralı denklemde, $G(x,y)$ önerilen yöntemde kullanılan iki boyutlu Gabor filtresini temsil etmektedir. Gabor filtresi beş parametreden oluşmaktadır: Gauss dağılımının standart sapması (σ), sinüs dalga boyu (λ), mekânsal en-boy oranı (γ), sinüzoidal fonksiyonun faz ofseti (Ψ) ve Gabor fonksiyonunun normali ile paralel şeritler arasındaki yönelim açısı (θ). Gabor filtresi, giriş görüntüsüne θ yönünde bir alçak geçiren filtre uygulayarak [20] ray görüntüsünün doğruluğunu artırmaktadır. Şekil 2, iki farklı ray görüntüsü için Gabor filtresi sonuçlarını göstermektedir.



Şekil 2. Gabor filtresi uygulanmadan önceki orijinal ray görüntüleri ve filtre sonrası iyileştirilmiş çıktılar

Şekil 2, Gabor filtresinin uygulanmasından önce ve sonra ray yüzeyinin görüntüsünü göstermekte olup, filtre görüntünün netliğini artırmaktadır. Ön işleme sonrasında ray kenarlarının tespiti için bir algoritma önerilmiştir. Bu yaklaşım, her sütundaki gri piksel değerlerini sırasıyla elde etmekte ve sütun değerlerinin toplamı arasındaki farkı hesaplayarak ray kenarlarını belirlemektedir. Ayrıca, kenar tespiti işlemi standart sapma değeri kullanılarak iki aşamada gerçekleştirilmiştir. Önerilen ray çıkarım algoritması Şekil 3'te gösterilmiştir.

```

Girdi: Orijinal bir giriş görüntüsü I

Çıktı: Ayıklanmış ray bölgesi Ir

[r, c] ← I görüntüsünün satır ve sütun sayıları

H ← sıfırlardan oluşan 1 × c boyutlu bir dizi

c sütunları üzerinde döngü:
  toplam ← 0
  r satırları üzerinde döngü:
    toplam ← toplam + I(i, j)
  döngü sonu
  H(j) ← H(j) + toplam
döngü sonu

D ← sıfırlardan oluşan 1 × (c-1) boyutlu dizi
STD ← sıfırlardan oluşan 1 × c boyutlu dizi

c sütunları üzerinde döngü:
  D(i) ← |H(i) - H(i-1)|
  STD(i) ← I(:, i) sütununun standart sapması
döngü sonu

leftB ← D dizisindeki en yüksek iki değerin daha küçük indeksi


S ← STD(leftB : c) < eşik değeri
rightB ← leftB + S içindeki **doğru** (true) değerlerin toplamı

Ir ← I(1:r, leftB : rightB) // Belirlenen sütun aralığındaki ray bölgesi

```

Şekil 3. Ray kenarlarının belirlenmesi için geliştirilen algoritmanın sözde kodu

Şekil 3'te alınan gri tonlamalı görüntüde, her sütundaki piksel değerleri hesaplanmaktadır. Ardından, ardışık sütunlardaki piksel değerlerinin toplamalarının ardışık farkları alınarak rayın sol ve sağ sınırları belirlenmektedir. Rayın sol sınırı net bir şekilde tanımlanırken, elde edilen görüntülerdeki düzensiz ışık dağılımı sağ ray sınırının belirlenmesini zorlaştırmaktadır. Bu nedenle, sağ ray sınırını seçmek için sol ray sınırından itibaren standart sapma değeri ile bir eşik değeri karşılaştırılmaktadır. Şekil 4, görüntüye uygulanan ray çıkarma algoritmasını göstermektedir.




Şekil 4. a) Ray görüntüsü ve hesaplanan D sinyali b) Her sütunun standart sapma değerleri

Şekil 4.a)'da ray çıkarma algoritmasında D sinyali elde edildikten sonra, en yüksek iki D sinyali değeri arasından daha düşük indeks değerine sahip olan seçilmektedir. Daha sonra, sol ray kenarından görüntünün sonuna kadar her sütun için hesaplanan standart sapma değerleri bir eşik değerinin altında toplanarak sağ ray kenarı belirlenmektedir. Elde edilen ray görüntüsü çıkarılarak bir dizine kaydedilmektedir.

2.2. Bulanık modelleme tabanlı kusur tespiti

Önerilen kusur tespit yaklaşımı, sağlıklı ray yüzeyini modellemek için bulanık ölçüm yöntemini kullanmaktadır. Özellikle, sağlıklı ray görüntüsünün histogramı Gauss fonksiyonu ile modellenmektedir. Aynı zamanda, sağlıklı ray yüzeyi modeli dışındaki alan da ayrı bir Gauss fonksiyonu ile modellenmektedir. Önerilen yaklaşım Şekil 5'te sunulmuştur. Bu çalışmada kullanılan bulanık entropi, belirsizliğin ölçülmesinde kullanılan bir bilgi kuramı metriğidir ve kusurlu bölgelerin ayırımında kullanılmaktadır. Sağlıklı ray histogramının Gauss modeli ile temsil edilmesi ve kusur tespit süreci şematize edilmiştir.




Şekil 5. Bulanık entropi tabanlı kusur tespit algoritmasının adımları

Şekil 5'te, ilk RGB görüntü gri tonlamalı bir görüntüye dönüştürülmüştür. Sağlıklı ray hattının histogramı, (5) numaralı denklemle gösterilebilen bir Gauss fonksiyonu olarak modellenmiştir.


$$(x, y) = \frac{y}{\sqrt{\pi}\sigma} e^{-\frac{(x-\mu)^2}{\sigma^2}} \quad (5)$$

(5) numaralı denklemde, μ ve σ sırasıyla ortalama ve standart sapma değerlerini temsil etmektedir. x ve y değerleri ise histogramdaki piksel değerleri ile her piksel değerinin frekansını göstermektedir. Histogramı modellemek için μ ve σ değerlerinin tahmin edilmesi gerekmektedir. Bu iki parametrenin tahmini için Neelder-Mead simplex yöntemi kullanılmıştır [21]. Yöntem, n boyutlu x vektörü için n noktalı bir simplex ile başlar. Noktalar öncelikle sıralanır. Her adımda en kötü nokta elenir ve yerine başka bir nokta eklenir. Şekil 6, sağlıklı ray görüntüsü için elde edilen Gauss fonksiyonuyla kusurlu rayın modellenmesini göstermektedir.



Şekil 6. Sağlıklı ve kusurlu ray yüzeyleri için oluşturulan bulanık üyelik fonksiyonları

Şekil 6'da sağlıklı ray modeli için elde edilen Gauss fonksiyonu, kusurlu raylar için bir üyelik fonksiyonu oluşturmaktadır. Bulanık üyelik fonksiyonları belirlendikten sonra, görüntüdeki her pikselin üyeliğine göre bir üyelik matrisi oluşturulmaktadır. Üyelik matrisinde, bir piksel ya kusurlu ya da sağlıklı üyelik grubuna ait olarak sınıflandırılmaktadır. Ardından, üyelik matrisi üzerinden parçalar tespit edilmekte ve kusurlar belirlenmektedir. Şekil 7, bağlantılı parçalar ile kusur tespit algoritmasını göstermektedir.




Şekil 7. Bulanık üyelik matrisine dayalı bağlantılı bileşen analizi ile kusur tespiti adımları

Şekil 7’de, test görüntüsünün histogramı alınarak iki bulanık üyelik fonksiyonuna verilmektedir. Daha sonra, her piksel için iki üyelik değeri hesaplanmakta ve maksimum değere göre piksel arka plan veya kusur olarak kabul edilmektedir. Bağlantılı parçaları belirlemek için görüntü üzerinde bir filtre kaydırılmakta ve komşu piksel değerlerine göre bağlantısız pikseller gürültü olarak değerlendirilmektedir. Ardından, oluşturulan ikili görüntüde kusurlu bölge blob analizi ile işaretlenmektedir.

3. CNN-BILSTM tabanlı kusur sınıflandırması

Kusurların bulanık ölçüm tabanlı yöntemle tespit edilmesinin ardından, kusur türünü sınıflandırmak için CNN-BILSTM ağı önerilmiştir. Önerilen hibrit yöntem iki aşamadan oluşmaktadır. Birinci aşamada kullanılan evrişim katmanlarıyla filtreleme yapılırken, BILSTM katmanları ile önceki gözlemlerin bellek elemanları arasındaki ilişki dikkate alınmaktadır. Önerilen CNN-BILSTM modeli Şekil 8’de gösterilmiştir.



Şekil 8. CNN-BILSTM mimarisine sahip kusur sınıflandırma modelinin katman yapısı

Şekil 8’de, evrişim katmanından sonra eklenen iki Yönlendirilmiş Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory- BILSTM) katmanı gösterilmektedir. İkinci evrişim katmanından sonra, girdilerin BILSTM katmanı için uygun formata getirilmesi amacıyla bir boyutlandırma işlemi gerçekleştirilmiştir. BILSTM ve LSTM, ardışık verileri işlemek için yaygın olarak kullanılan tekrarlayan sinir ağlarıdır (Recurrent Neural Networks- RNN). Geleneksel sinir ağlarının aksine, RNN’ler giriş verileri arasında ilişki olduğunda ardışık verileri modellemektedir. LSTM modeli, RNN modellerinde ortaya çıkan kaybolan gradyan (vanishing gradient) sorununu çözmektedir. BILSTM ise verileri hem ileri hem de geri yönde ele alarak veriler arasındaki ilişkiyi iki yönlü olarak analiz etmektedir. Oluşturulan ağ modeline ait parametreler Tablo 1’de verilmiştir.


Tablo 1. BILSTM-CNN mimarisinin parametreleri

Katman	Filtre	Kernel Boyutu	Diğer	Bellek Birimi
2D Conv+Relu	16	5x5	-	-
2DMaxpool	-	5x5	Adım:2	-
2D Conv+Relu	32	5x5	-	-
Reshape	-	-	-	-
BILSTM	-	-	-	32
Dropout	-	-	Oran:0.4	-
BILSTM	-	-	-	64
Dropout	-	-	Oran:0.4	-
Dense	-	-	-	256
Dropout	-	-	Oran:0.3	-
Dense	-	-	-	1024
Dropout	-	-	Oran:0.3	-
Softmax	-	-	-	3

Tablo 1’de sunulan ağ modeli, iki ardışık BILSTM katmanından elde edilen ara çıktıları tam bağlantılı (fully connected) katmana giriş olarak kullanmaktadır. Önerilen mimaride kullanılan filtre sayıları, çekirdek (kernel) boyutları ve bellek birimi sayıları, geliştirme sürecinde gerçekleştirilen deneysel çalışmalar doğrultusunda belirlenmiştir.


4. Bulgular

Önerilen yaklaşım iki farklı veri kümesi üzerinde test edilmiştir. İlk olarak, RSDD-I ve RSDD-II olmak üzere iki bölümden oluşan Demiryolu Yüzey Kusur Veri Kümesi (Rail Surface Defect Dataset – RSDD) üzerinde değerlendirmeler gerçekleştirilmiştir. RSDD-I veri kümesi, her biri 1000x160 piksel boyutlarında olan 67 görüntüden oluşmaktadır. RSDD-II veri kümesi ise ağır hizmet yollarından elde edilen, her biri 1250x55 piksel boyutlarında olan 128 görüntüyü içermektedir. Her iki veri kümesine ait örnek görüntüler Şekil 9’da sunulmaktadır.



Şekil 9. Kusur tespiti için kullanılan veri kümelerine ait örnek görüntüler: a) RSDD-I b) RSDD-II

Şekil 9’da gösterilen her iki veri kümesinde de kusurlu bölgelerin gürültüyle karışma olasılığı yüksektir. Bu nedenle, ön işleme uygulanmış görüntüler üzerinde bulanık modelleme tabanlı bir kusur tespit sistemi kullanılmaktadır. RSDD-I ve RSDD-II veri kümelerine ait bazı görüntüler için kusur tespit sistemi Şekil 10’da gösterilmektedir.



Şekil 10. a) RSDD-I b) RSDD-II görüntüleri üzerinde bulanık modelleme ile kusur tespiti sonuçları

Şekil 10'da gösterildiği üzere, Gabor yöntemiyle gerçekleştirilen ön işlem sonrasında, kusurların daha kolay modellenebildiği bir görüntü elde edilmiştir. Gabor yöntemine ait parametreler Tablo 2'de verilmiştir.

Tablo 2. Gabor yönteminde kullanılan parametreleri

Parametre	Değer
Kernel boyutu	5
σ	5
θ	$\pi/4$
λ	$11 * \pi/4$
γ	0.5
ψ	1.24

Tablo 2'de verilen parametreler ile elde edilen ön işleme tabi tutulmuş görüntü, sağlıklı bir rayın histogram modelini elde etmek amacıyla bulanık üyelik modellemesine tabi tutulmuştur. Şekil 10'da yer alan bazı görüntülerde kusurlu bölgeye yakın alanlarda gürültü bulunmasına rağmen, ön işleme adımı bu gürültüleri başarıyla ortadan kaldırmıştır. Önerilen yaklaşımın RSDD-I ve RSDD-II veri kümeleri üzerindeki performansı, literatürde yer alan bazı görüntü işleme ve derin öğrenme tabanlı segmentasyon teknikleri ile karşılaştırılmıştır. RSDD-I ve RSDD-II veri kümeleri için karşılaştırma metriklerine ait sonuçlar Tablo 3'te sunulmuştur.



Tablo 3. RSDD-I/RSDD-II veri setlerindeki performans karşılaştırmaları


Veri Sei	Metot	PR	RC	F1	PR*	RC*	F1*
		Piksel Seviyesi			Kusur Seviyesi		
RSDD-I	MSFM [22]	0.37	0.43	0.36	0.76	0.25	0.38
	CTFM [23]	0.86	0.77	0.80	0.84	0.77	0.80
	Segnet [24]	0.84	0.65	0.68	0.37	0.57	0.45
	Unet++[25]	0.90	0.67	0.74	0.79	0.61	0.69
	PSPnet[26]	0.75	0.73	0.72	0.63	0.73	0.67
	Bizim	0.82	0.78	0.80	0.91	0.89	0.90
RSDD-II	MSFM [22]	0.61	0.64	0.59	0.86	0.71	0.78
	CTFM [23]	0.84	0.73	0.76	0.85	0.83	0.84
	Segnet [24]	0.70	0.68	0.64	0.54	0.68	0.60
	Unet++[25]	0.60	0.77	0.62	0.39	0.74	0.51
	PSPnet[26]	0.68	0.79	0.71	0.74	0.80	0.77
	Bizim	0.85	0.69	0.74	0.85	0.95	0.90

Tablo 3'te Coarse-to-Fine Model (CTFM), kusurlu bölgeleri üç aşamada tanımlamaktadır: arka plan modelinin çıkarılması, görsel belirginlik tahmini ve son aşamada piksel çıkarım yöntemi. Ancak bu yöntemin bir dezavantajı, her bir aşamada ayrı parametre ayarlarının gerekliliğidir. CTFM, yalnızca PR değeri açısından önerilen yaklaşımdan daha iyi performans göstermektedir. Çoklu Özellik Belirginlik Birleştirme Yöntemi (MSFM), ray yüzeyi kusurlarını tespit etmek için belirginlik tahmini kullanmaktadır. Belirginlik görüntüsü elde edildikten sonra, görüntüyü bölütlemek ve kümelemek amacıyla mean-shift algoritması ve uyarlamalı eşikleme yöntemleri uygulanmıştır. Ayrıca, Segnet, Unet++ ve PSPnet gibi yaygın bölütleme yöntemleri de bu veri seti üzerinde uygulanmıştır. Önerilen yaklaşım, bu yöntemlerin tümünden daha iyi performans sergilemektedir. Bu veri seti yalnızca kusurlu örnekler içerdiğinden ve veri setinin boyutu nispeten küçük olduğundan, sınıflandırma işlemi gerçekleştirilmemiştir.


İkinci veri seti, biri sağlıklı sınıf olmak üzere toplam dört sınıftan oluşmaktadır; diğer kusurlar Squat, Joint ve Severe Squat olarak etiketlenmiştir. Veri seti, bir ölçüm treninin altından alınan görüntülerle oluşturulmuştur. Tablo 4'te, veri setinden bazı örnekler ve bunlara karşılık gelen örnek sayıları verilmiştir.

Tablo 4. Demiryolu yüzey kusuru veri seti

Etiket	Örnek	Örnek Sayısı
Sağlıklı		492
Ekleme		491
Göçme		713

Şiddetli		330
Göçme		

Tablo 4’te verilen veriler toplam 2068 örnekten oluşmaktadır. Bu veri seti için Ground Truth (gerçek etiket) bilgileri oluşturulmamıştır. Önerilen bulanık ölçüm yöntemi, düşük çözünürlük ve zayıf aydınlatma koşulları altında bu veri seti üzerinde test edilmiştir. Önerilen yaklaşımın örnek görüntüler üzerindeki sonuçları Şekil 11’de sunulmuştur.



Şekil 11. Özgün veri setimizdeki üç farklı kusur türü için tespit sonuçları: a) Eklem b) Göçme c) Şiddetli Göçme

Şekil 11, bulanık üyelik modellemesinin çeşitli kusur türleri için kusurlu bölgeleri doğru bir şekilde tespit ettiğini göstermektedir. Ayrıca, düşük kaliteli görüntüler üzerinde uygulanan ön işleme adımıyla elde edilen yeni görüntü, kusurlu bölgelerin bölütlenmesini mümkün kılmaktadır. RSDD veri setinden farklı olarak, bu veri seti hem sağlıklı örnekler hem de çeşitli kusur sınıflarını içermektedir. Bununla birlikte, veri seti sınıflandırma amacıyla toplandığı için Ground Truth (gerçek etiket) görüntülerini içermemektedir. Bir görüntü bölütlendikten sonra, kusurlu bölge blob analizi ile işaretlenmektedir. Blob analizinden elde edilen kusurlu bölgenin boyutu, deneme-yanılma yöntemiyle belirlenen 10 piksel eşik değeriyle karşılaştırılmaktadır. Kusurlu alan boyutu bu eşik değeri aştığında, görüntü kusurlu olarak işaretlenmektedir. Tahmin sonuçlarına ilişkin performans ölçütleri Tablo 5’te sunulmuştur.

Tablo 5. Bulanık modellemenin kusur tespit oranı


Sınıf	Sağlıklı	Kusurlu	Tespit Oranı (%)
Sağlıklı	480	12	97.56
Göçme	1	713	99.85
Eklem	2	489	99.59
Şiddetli Göçme	5	325	98.48
Ortalama Tespit Oranı			98.87

Tablo 5, kusur tespit oranının yüksek olduğunu ve sağlıklı olarak işaretlenen görüntüler için yanlış tespit oranının oldukça düşük olduğunu göstermektedir. Sağlıklı olarak etiketlenen görüntülerin kusurlu olarak tespit edilmemesi büyük önem taşımaktadır. Ray yüzeyindeki kusurlar belirlendikten sonra, bir sonraki aşamada kusur türünün sınıflandırılmasında CNN-BILSTM yöntemi kullanılmaktadır. Önerilen ağız parametreleri Tablo 6’da verilmiştir.


Tablo 6. CNN-BILSTM'nin eğitim parametreleri

Parametre	Değer
Girdi Boyutu	224x224
Optimizasyon Fonksiyonu	Adam
Momentum	0.9
Öğrenme Oranı	1e-4
Minumun Batch Boyutu	32
Maksimum Döngü	80

Temel CNN ve CNN-BILSTM modelleri, Tablo 6’da verilen parametreler kullanılarak eğitilmiştir. Özellikle, önerilen CNN-BILSTM modeli yalnızca 1,7 milyon parametre içermektedir. Şekil 12, eğitim ve doğrulama süreçlerine ait doğruluk oranı ve kayıp grafikleri göstermektedir.

**Şekil 12.** CNN ve CNN-BILSTM modellerine ait eğitim/doğrulama doğruluk ve kayıp eğrileri

Şekil 12, CNN-BILSTM modelinin temel CNN modeline kıyasla daha erken yakınsadığını ve hem eğitim hem de doğrulama doğruluğunun daha yüksek olduğunu göstermektedir. Şekil 12’de görülen doğruluk eğrisi, modelin eğitim ve doğrulama verileri üzerindeki başarı oranını; kayıp eğrisi ise modelin öğrenme sürecindeki hata düzeyini göstermektedir. Buna ek olarak, Şekil 13 her iki modele ait karmaşıklık matrislerini sunmaktadır. Her bir sınıfa ait doğru ve yanlış sınıflandırma sonuçları karışıklık matrisleri ile sunulurken model başarımı görselleştirilmiştir.



Şekil 13. a) CNN ve b) CNN-BILSTM modellerine ait karışıklık matrisleri

Şekil 13'te gösterilen karmaşıklık matrislerinden her bir sınıf için doğruluk (accuracy), kesinlik (precision, PR), duyarlılık (recall, RC) ve F1 skoru hesaplanmıştır. Tablo 7, bu değerlendirme ölçütleri açısından iki yöntemin performansını karşılaştırmalı olarak sunmaktadır.

Tablo 7. İki CNN modeli için performans ölçümlerinin karşılaştırılması

Metot	Sınıf	PR	RC	F1	Doğruluk
CNN	Şiddetli Göçme	0.93	0.92	0.93	0.93
	Eklem	0.86	1.00	0.93	
	Göçme	0.96	0.92	0.94	
CNN-BILSTM	Şiddetli Göçme	0.94	0.98	0.96	0.98
	Eklem	1.00	1.00	1.00	
	Göçme	0.98	0.96	0.97	

Tablo 7, önerilen CNN-BILSTM modelinin tüm değerlendirme ölçütleri ve doğruluk açısından temel CNN modelinden daha iyi performans gösterdiğini ortaya koymaktadır. Önceki birçok çalışmada, araştırmacılar kendi veri setlerini kullanarak kusur tespiti yöntemleri önermiştir. Bu çalışmada ise veri seti bir ölçüm treninden toplanmış olup, literatürde halka açık olarak yalnızca RSDD veri seti bulunduğundan, bu veri seti karşılaştırma amacıyla kullanılmıştır. Önerilen yaklaşım ayrıca literatürdeki çalışmalarla da karşılaştırılmış ve bu karşılaştırmanın sonuçları Tablo 8'de sunulmuştur.

Tablo 8. İki CNN modeli için performans ölçümlerinin karşılaştırılması

Referans	Metot	Kusur	Doğruluk (%)
[1]	DenseNet+ Manuel özellikler	3	93.80
[15]	GrabCut+ YOLOv2	1	97.11
[18]	MobileNetv2+ YOLACT	4	93.50
[19]	MobileNetV2+SqueezeNet	3	97.11
[27]	Piramitsel özellikler + LWCNN	1	81.41
[28]	Bölümlenmiş kenar özellikleri	1	92.03
[29]	Piksel düzeyinde derin segmentasyon	1	96.20
[30]	CNN modeli	5	91.11
Bizim	Bulanık Modelleme + CNN-BILSTM	3	98.00

Tablo 8, tespit edilen kusur sayısını sunmaktadır. [1] numaralı çalışmada, özellik çıkarımı için DenseNet ile kombine edilen görüntü işleme tabanlı yöntemler kullanılmıştır. Ancak, ağırlık büyüklüğü ve ek özellik çıkarma aşaması nedeniyle, önerilen sistemin gerçek zamanlı uygulaması sınırlı olabilir. [15] numaralı çalışmada, kusurlu bölgenin görüntü segmentasyonu temelinde elde edilmesi için GrubCut ve YOLOv2 modeli kullanılmış, ardından kusur YOLOv2 ile tespit

edilmiştir. Ayrıca, [18] referansında ray ve kelepçe kusurları eş zamanlı olarak tespit edilmiştir. Ray kusurlarını tespit etmek için YOLACT tabanlı segmentasyon algoritması kullanılmıştır. RSDD veri setini analiz etmek için piramit özellikler ve hafif yapılı CNN [27] yöntemi uygulanmıştır. Ancak, veri setindeki örnek sayısının sınırlı olması nedeniyle derin öğrenme modelinin genelleme yeteneği düşük olmuştur. Bölümlenmiş kenar özellikleri [28] ray kusurlarının tespiti için hassas eşik değerlerine ihtiyaç duymakta olup, gürültülü görüntülerde yanlış tespit olasılığını artırmaktadır. Kusur tespit performansını artırmak amacıyla, rezidüel tabanlı dikkat ağı ve LSTM tabanlı konvolüsyonel sinir ağı önerilmiştir [29]. Bu çalışma yalnızca kusurun varlığını belirlemiştir. [30] numaralı çalışmada ise çeşitli kusur türlerini sınıflandırmak için özel bir CNN modeli önerilmiştir. Önerilen ağ yapısının performansı, tekli ve çoklu kusur türü sınıflandırmaları için değerlendirilmiştir. [17] çalışmasında, iki hafif ağdan elde edilen özellikler destek vektör makineleri ile sınıflandırılarak kusur türü belirlenmiştir. Bu çalışmada önerilen yaklaşım hem kusur tespiti hem de kusur türü sınıflandırması için iki aşamalı bir yöntemden oluşmaktadır. Önerilen bulanık modellemeye dayalı kusur tespit yöntemi, ön işleme nedeniyle görüntüdeki gürültüden etkilenmemektedir. Ayrıca, kusurlar belirlendikten sonra sınıflandırma aşamasında kullanılan CNN-BILSTM modeli, hızlı yakınsama ve hafif yapısı sayesinde gerçek zamanlı uygulamalarda kullanılabilir niteliktedir.

5. Sonuç

Bu çalışma, ray yüzey kusurlarının tespitine yönelik iki aşamalı bir yaklaşım sunmaktadır. Birinci aşamada, sağlıklı ve kusurlu ray yüzeylerini ayırt etmek amacıyla, ön işleme tabi tutulmuş görüntülerde kusurları belirlemek için bulanık modellemeye dayalı bir yöntem önerilmektedir. Önerilen Gabor filtresi, yüksek kontrastlı ve düşük gürültülü bir görüntü elde etmeyi sağlamaktadır. Sağlıklı durumu karakterize etmek için tek bir görüntü örneği üzerinde histogram modellemesi gerçekleştirilirken, histogramın kalan kısmı kusurlu durumları modellemektedir. Bu iki histogram, bulanık üyelik fonksiyonları olarak kullanılmaktadır. Kusurlar, bulanık üyelik fonksiyonlarıyla işlenen görüntüden elde edilen ikili (binary) görüntüdeki bağlı bileşenlerin değerlendirilmesiyle tespit edilmektedir. Önerilen yöntemin literatürdeki çalışmalardan daha yüksek performans göstermesinin başlıca nedeni, gürültüye karşı dayanıklı bulanık modelleme yaklaşımı ve CNN-BILSTM mimarisinin birlikte kullanılmasıdır. Bu sayede hem kusur tespiti hem de sınıflandırma görevlerinde yüksek doğruluk elde edilmiştir. Ayrıca modelin düşük parametre sayısı, gerçek zamanlı uygulamalar için uygunluk sağlamaktadır. Çalışmanın temel katkısı, yalnızca tek bir sağlıklı görüntüden elde edilen model kullanılarak kusurların saptanmasıdır. Ayrıca, önerilen ön işleme yöntemi, görüntüdeki gürültü ve aydınlatma problemlerini ortadan kaldırmaktadır. Yanlışlıkla kusur olarak tespit edilen gürültü ise bağlı bileşenler yöntemiyle elenmektedir. Kusurlu görüntüler belirlendikten sonra, kusur türü önerilen CNN-BILSTM modeli ile sınıflandırılmaktadır. Bu hafif ağ modeli, temel CNN modeline göre daha hızlı yakınsamaya sahiptir. Önerilen yaklaşım, literatürde rapor edilen yöntemlere kıyasla farklı kusur türlerini daha başarılı bir şekilde tespit etmektedir. Literatürde iki aşamalı yapı öneren bazı çalışmalar (ör. [17], [19]) bulunsada bu çalışmanın özgün yönü, yalnızca tek bir sağlıklı görüntü üzerinden bulanık histogram modellemesiyle kusur segmentasyonu yapılması ve düşük çözünürlüklü, gürültülü görüntülerde dahi yüksek doğruluk sağlayan CNN-BILSTM mimarisi ile sınıflandırma işleminin gerçekleştirilmesidir. Gelecek çalışmalarda, kusur şiddetinin tahmini ve yöntemin mobil denetim sistemlerine entegrasyonu üzerinde durulması önerilmektedir.

Kaynakça

- [1] L. Zhuang, H. Qi, & Z. Zhang, "The automatic rail surface multi-flaw identification based on a deep learning powered framework," IEEE Trans. Intell. Transp. Syst., 2021.
- [2] H. Yang, Y. Wang, J. Hu, J. He, Z. Yao, & Q. Bi, "Segmentation of track surface defects based on machine vision and neural networks," IEEE Sensors J., vol. 22, no. 2, pp. 1571–1582, 2021.

- [3] M. Sevi, İ. Aydın, E. Akin, "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.
- [4] M. Guerrieri, G. Parla, & C. Celauro, "Digital image analysis technique for measuring railway track defects and ballast gradation," *Measurement*, vol. 113, pp. 137-147, 2018.
- [5] Y. Jiang et al., "Non-contact ultrasonic detection of rail surface defects in different depths," in 2018 IEEE Far East NDT New Technology & Application Forum (FENDT), pp. 46-49, IEEE, 2018.
- [6] G. Piao, J. Li, L. Udpal, J. Qian, & Y. Deng, "Finite-element study of motion-induced eddy current array method for high-speed rail defects detection," *IEEE Trans. Magn.*, vol. 57, no. 12, pp. 1-10, 2021.
- [7] Y. Santur, M. Karaköse, & E. Akin, "A new rail inspection method based on deep learning using laser cameras," in 2017 Int. Artificial Intelligence and Data Processing Symposium (IDAP), pp. 1-6, IEEE, 2017.
- [8] H. Zhong, L. Liu, J. Wang, Q. Fu, & B. Yi, "A real-time railway fastener inspection method using the lightweight depth estimation network," *Measurement*, vol. 189, p. 110613, 2022.
- [9] H. Wang, M. Li, & Z. Wan, "Rail surface defect detection based on improved Mask R-CNN," *Comput. Electr. Eng.*, vol. 102, p. 108269, 2022.
- [10] J. Gan, J. Wang, H. Yu, Q. Li, & Z. Shi, "Online rail surface inspection utilizing spatial consistency and continuity," *IEEE Trans. Syst., Man, Cybern.: Syst.*, vol. 50, no. 7, pp. 2741-2751, 2018.
- [11] H. Zhang et al., "Automatic visual detection system of railway surface defects with curvature filter and improved Gaussian mixture model," *IEEE Trans. Instrum. Meas.*, vol. 67, no. 7, pp. 1593-1608, 2018.
- [12] D. Zhang et al., "Two deep learning networks for rail surface defect inspection of limited samples with line-level label," *IEEE Trans. Ind. Informat.*, vol. 17, no. 10, pp. 6731-6741, 2020.
- [13] Z. Zhang, M. Liang, and Z. Wang, "A deep extractor for visual rail surface inspection," *IEEE Access*, vol. 9, pp. 21798-21809, 2021.
- [14] Y. Wu et al., "Hybrid deep learning architecture for rail surface segmentation and surface defect detection," *Comput.-Aided Civ. Infrastruct. Eng.*, vol. 37, no. 2, pp. 227-244, 2022.
- [15] H. Yang et al., "Deep learning and machine vision-based inspection of rail surface defects," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1-14, 2021.
- [16] H. Li et al., "Ensemble model for rail surface defects detection," *PLoS One*, vol. 17, no. 5, p. e0268518, 2022.
- [17] İ. Aydın & E. Akin, "Two-stage rail defect classification based on fuzzy measure and convolutional neural networks," in *Intelligent and Fuzzy Systems: Digital Acceleration and The New Normal- Proceedings of the INFUS 2022 Conf.*, vol. 1, pp. 769-776, Springer, Cham, 2022.
- [18] Z. Tu, S. Wu, G. Kang, & J. Lin, "Real-time defect detection of track components: Considering class imbalance and subtle difference between classes," *IEEE Trans. Instrum. Meas.*, vol. 70, pp. 1-12, 2021.
- [19] İ. Aydın, E. Akin, & M. Karaköse, "Defect classification based on deep features for railway tracks in sustainable transportation," *Appl. Soft Comput.*, vol. 111, p. 107706, 2021.
- [20] A. K. Jain & F. Farrokhnia, "Unsupervised texture segmentation using Gabor filters," *Pattern Recognit.*, vol. 24, no. 12, pp. 1167-1186, 1991.
- [21] J. C. Lagarias, J. A. Reeds, M. H. Wright, & P. E. Wright, "Convergence properties of the Nelder-Mead simplex method in low dimensions," *SIAM J. Optim.*, vol. 9, no. 1, pp. 112-147, 1998.
- [22] H. Zhai & Z. Ma, "Detection algorithm of rail surface defects based on multifeature saliency fusion method," *Sensor Rev.*, ahead-of-print, 2022.
- [23] H. Yu et al., "A coarse-to-fine model for rail surface defect detection," *IEEE Trans. Instrum. Meas.*, vol. 68, no. 3, pp. 656-666, 2018.
- [24] V. Badrinarayanan, A. Handa, and R. Cipolla, "Segnet: A deep convolutional encoder-decoder architecture for robust semantic pixel-wise labelling," *arXiv preprint arXiv:1505.07293*, 2015.
- [25] Z. Zhou, M. M. Rahman Siddiquee, N. Tajbakhsh, & J. Liang, "Unet++: A nested u-net architecture for medical image segmentation," in *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, pp. 3-11, Springer, Cham, 2018.
- [26] H. Zhao, J. Shi, X. Qi, X. Wang, & J. Jia, "Pyramid scene parsing network," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, pp. 2881-2890, 2017.
- [27] Y. Liu, H. Xiao, J. Xu, & J. Zhao, "A rail surface defect detection method based on pyramid feature and lightweight convolutional neural network," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1-10, 2022.
- [28] X. Ni, H. Liu, Z. Ma, C. Wang, & J. Liu, "Detection for rail surface defects via partitioned edge feature," *IEEE Trans. Intell. Transp. Syst.*, 2021.
- [29] L. Yang, S. Xu, J. Fan, E. Li, & Y. Liu, "A pixel-level deep segmentation network for automatic defect detection," *Expert Syst. Appl.*, vol. 215, p. 119388, 2023.

- [30] S. Faghih-Roohi, S. Hajizadeh, A. Núñez, R. Babuska, & B. De Schutter, “Deep convolutional neural networks for detection of rail surface defects,” in 2016 Int. Joint Conf. Neural Netw. (IJCNN), pp. 2584–2589, IEEE, 2016.

Özgeçmiş



İlhan AYDIN

Prof. Dr. İlhan Aydın, 1981 yılında Elazığ’da doğmuştur. Lisans ve yüksek lisans eğitimini sırasıyla 2001 ve 2006 yıllarında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü’nde tamamlamıştır. Doktora derecesini ise 2011 yılında Fırat Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü’nden almıştır. Halen Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü’nde profesör olarak görev yapmaktadır. Araştırma ilgi alanları arasında optimizasyon, gerçek zamanlı sistemler, arıza teşhisi ve durum izleme, sinyal ve görüntü işleme ile derin öğrenme yer almaktadır.

E-Posta: iaydin@firat.edu.tr



Mehmet SEVİ

Mehmet Sevi, 1988 yılında Denizli’de doğmuştur. Lisans eğitimini Doğu Akdeniz Üniversitesi Bilgisayar Mühendisliği Bölümü’nde, yüksek lisans eğitimini ise Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü’nde tamamlamıştır. Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü’nde doktora eğitimini tamamlamıştır. Araştırma ilgi alanları arasında görüntü işleme ve derin öğrenme bulunmaktadır. Ayrıca, Muş Alparslan Üniversitesi Bilgi İşlem Daire Başkanlığında Daire Başkanı olarak görev yapmaktadır.

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



Erhan AKIN

Prof. Dr. Erhan Akın, lisans eğitimini 1984 yılında Elazığ Fırat Üniversitesi Elektrik Mühendisliği Bölümü’nde, yüksek lisans eğitimini 1987 yılında aynı üniversitenin Bilgisayar Mühendisliği Bölümü’nde tamamlamış, doktora derecesini ise 1994 yılında Fırat Üniversitesi Elektrik Mühendisliği Bölümü’nden almıştır. Halen Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü’nde Profesör Doktor olarak görev yapmakta olup, aynı bölümün başkanlığını yürütmektedir. Araştırma alanları arasında yumuşak hesaplama, elektrik motor sürücüler, bulanık kümeler ve sistemler, doğrusal olmayan kontrol sistemleri, arıza teşhisi ve bilgisayarlı görme bulunmaktadır.

E-Posta: eakin@firat.edu.tr

Beyanlar:

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Yazarların katkıları: İlhan AYDIN: Metot, kaynaklar, görselleştirme, yazma-orijinal taslak hazırlama. Mehmet SEVİ: Kontrol, yazma-gözden geçirme ve düzenleme, inceleme. Erhan AKIN: Kontrol, yazma-gözden geçirme ve düzenleme, inceleme.