

## Demiryolu Bağlantı Elemanları için Anahtar Noktalar ve Görsel Kelime Çantası Tabanlı Kusur Tespit Yöntemi

İlhan AYDIN<sup>1\*</sup>, Emre GÜÇLÜ<sup>2</sup>, Erhan AKIN<sup>3</sup>

<sup>1,2,3</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye  
<sup>\*1</sup> iaydin@firat.edu.tr, <sup>2</sup> emreguclu1367@gmail.com, <sup>3</sup> eakin@firat.edu.tr

(Geliş/Received: 10/03/2021;

Kabul/Accepted: 05/04/2021)

**Öz:** Demiryolu hattı; raylar, ray traversleri ve bağlantı elemanlarından oluşan stabil bir yapıdır. Bu yapı tekerlekler için güvenilir bir yüzey sağlayarak trenlerin taşınmasını sağlar. Eğer bu yapı bozulursa güvenlik sorunları ortaya çıkar. Bu nedenle hat üzerinde oluşabilecek kusurların incelenmesi önemli bir konu haline gelmiştir. Bu çalışmada, ray bağlantı elemanlarında oluşan kusurların tespiti için bilgisayarlı görme tabanlı bir yaklaşım önerilmiştir. Önerilen yaklaşımda ilk olarak ray görüntüsünden bağlantı elemanının konumunu belirlenmektedir. Daha sonra bağlantı elemanı ile ilgili tanımlayıcı özellikler Oriented Fast and Rotated Brief (ORB) yöntemi ile elde edilmektedir. Son aşamada ise elde edilen özellikler kullanılarak bağlantı elemanı için kusurlu veya sağlam olarak sınıflandırma işlemi yapılmaktadır. Önerilen yöntemin başarımı deneysel olarak doğrulanmış ve %96.48'lik bir başarımla elde edilmiştir. Aynı veri kümesi üzerinde Speeded-Up Robust Features (SURF) anahtar nokta çıkarım tekniği ve Histogram of Oriented Gradients (HOG) tekniği de uygulanmıştır. Üç tekniğin sonuçları karşılaştırılmıştır. Ayrıca elde edilen sonuç, literatürde bulunan farklı çalışmaların sonuçları ile karşılaştırılıp tablo halinde sunulmuştur.

**Anahtar kelimeler:** Demiryolu bağlantı elemanı, bilgisayarlı görme, ORB yöntemi, görsel kelime çantası, kusur tespiti.

### Key points and Bag of Visual Words Based Defect Detection Method for Railway Fasteners

**Abstract:** Railway track is a stable structure consisting of rails, rail sleepers and fasteners. This structure enables trains to be transported by providing a reliable surface for the wheels. If this structure is broken, security problems arise. For this reason, it has become an important issue to examine the defects that may occur on the line. In this study, a computer vision-based approach is proposed for the detection of defects in rail fasteners. The proposed approach first determines the position of the fastener from the rail image. Then, the descriptive properties of the fastener are obtained by the Oriented Fast Rotated Brief Oriented Fast and Rotated Brief (ORB) method. In the last stage, using the obtained features, the fastener classification process is made as defected or robust. The success of the proposed method has been experimentally verified and a success of 96.88% has been achieved. üzerinde Speeded-Up Robust Features (SURF) key point extraction technique and Histogram of Oriented Gradients (HOG) technique were also applied on the same dataset. The results of the three techniques are compared. In addition, the result obtained was compared with the results of different studies in the literature and presented in a table.

**Key words:** Railway fastener, computer vision, ORB method, visual word bag, defect detection.

### 1. Giriş

Demiryolları raylar üzerinde ilerleyen araçlarla yolcu ve yük taşımacılığının yapılmasını sağlayan yapılardır. Demiryolu taşımacılığı günümüzde en çok kullanılan yöntemlerden biridir. Bu nedenle, kazalara yol açabilecek kusurların tespiti için demiryolu denetimi önemli bir konudur. Raylar üzerinde kullanıma bağlı olarak çeşitli arızalar meydana gelmektedir. Bu arızalar; ray yüzeyindeki bozulmalar, eksik bağlantı elemanları, traverslerin yanlış konumlanması gibi durumlardır [1]. Travers rayların altına dik olarak belirli aralıklarla yerleştirilen ve ray üzerindeki kuvveti balast tabakasına yayan beton veya ahşap olarak imal edilen bloklardır. Demiryollarında yapılan kusur incelemelerinde genel olarak rayların ve ray bağlantı elemanlarının durumu incelenir.

Demiryolu endüstrisi, şu anda güvenli bir demiryolu ulaşımı sağlamak için bir dizi kusur inceleme uygulaması kullanmaktadır. Bu uygulamalardan biri görsel incelemedir. Görsel inceleme ile kusur tespiti için deneyimli çalışanlar ve uygun eğitim gerekir. Ayrıca, görsel incelemeler yoğun uğraş gerektirir ve kusuru yorumlayan kişinin yorumlarına göre değişken ve özeldir. Görsel incelemelere ek olarak ultrasonik ray kusur tespiti [2] ve demiryolu geometri ölçüm sistemleri [3] gibi inceleme yöntemleri de bulunmaktadır. Ancak bu yöntemler oldukça pahalıdır ve denetleme yılda sadece birkaç kez gerçekleşir. Bu nedenle, hatayı tespit etmek için


\* Sorumlu yazar: [iaydin@firat.edu.tr](mailto:iaydin@firat.edu.tr). Yazarların ORCID Numaraları: <sup>1</sup> 0000-0001-6880-4935, <sup>2</sup> 0000-0002-4566-7517, <sup>3</sup> 0000-0001-6476-9255

tespit süresini kısaltabilecek yeni bir yöntemin geliştirilmesine ihtiyaç vardır. Temassız, düşük maliyetli, yüksek hız avantajlarına sahip görüntü işleme teknolojisi bu iş için uygun bir yöntemdir. Son yıllarda, bilgisayarın hesaplama gücünün daha iyi olması ile birlikte görme tabanlı inceleme çalışmaları artmıştır. Ray yüzeyinde oluşan kusurların belirlenmesi için görüntü işleme ve derin öğrenme tabanlı teknikler önerilmiştir [4-6]. Ray kusurlarının tespiti için önerilen yöntem, hattın belirli uzamsal özelliklerini alarak az sayıda yakın değer içeren bir arka plan istatistiksel dağılımını kullanır. Vidalarda oluşan kusurların tespiti için benzerliğe dayalı bir derin ağ modeli önerilmiştir [7]. Derin öğrenme tabanlı teknikler gerçek zamanlı uygulandığında pahalı ekran kartlarına ihtiyaç duyarlar ve gerçek zamanlı uygulamalar için görüntü alma hızı ile ilgili problemler oluşur. Önerilen yöntem ile hem bağlantı elemanının lokalizasyonu belirlenmekte hem de bağlantı elemanlarını sınıflandırması sağlanmaktadır. Kısmen aşınmış veya tamamen eksik bağlantı elemanlarını olasılık temelli konu modeli kullanarak tespiti için görsel algılama tabanlı bir yöntem önerilmiştir [8]. Bağlantı elemanlarını modellemek için olasılıksal yapı modeli önerilmiş ve sınıflandırma için Haar benzeri bir özellik çıkarımı kullanılmıştır. Lazer kameralar ile alınan ray görüntülerinden bağlantı elemanın tespiti için histogram tabanlı bir yöntem önerilmiştir [9]. Önerilen yöntem histogram tepe kontrol yöntemi ile temel bileşen analizini birleştiren hibrit bir yaklaşıma dayanmaktadır. Bağlantı elemanlarında oluşan kusurların belirlenmesi için karşılaştırmalı görme tabanlı bir yöntem önerilmiştir [10]. Kusurlu eleman tespiti için Dense-SIFT ve evrişimsel sinir ağı tabanlı iki teknik karşılaştırılmıştır. Sonuçlar Dense-SIFT'in daha iyi olduğunu göstermiştir. Farklı aydınlanma koşulları altında bağlantı elemanının tespiti ve kusurlarına göre sınıflandırılması için yönlendirilmiş gradyan histogramı ve bulanık kümeleme tabanlı bir teknik önerilmiştir [11]. Önerilen yöntem ile farklı noktalarda kusurlu olan bağlantı elemanın tespiti ve sınıflandırılması sağlanmıştır. Bağlantı elemanlarında kusur tespiti için evrişimsel sinir ağı tabanlı bir yöntem önerilmiştir [12]. Önerilen yöntemin temel katkısı bir bölütleme algoritması ile bağlantı elemanının ray bağlantı civatası ve bağlantı klipsi olarak iki parçaya bölünmesi ve klipsleri tespit etmek için lokal evrişimsel bir sinir ağının kullanılmasıdır.

Literatürde bağlantı elemanı kusur tespiti için birçok yöntem önerilmesine rağmen halen bütün şartlarda çalışan tamamen otomatik bir yöntem bulunmamaktadır. Birçok çalışmada ise bağlantı elemanının nasıl tespit edildiği ile ilgili oldukça az bilgi verilmektedir. Bu çalışmada ray bağlantı elemanı kusurlarının tespiti için yeni bir yöntem önerilmiştir. Önerilen yöntem ilk olarak ışıklandırma ile ilgili gürültüleri yok etmek için yüksek kontrastlı bir görüntü elde etmektedir. Bu görüntüde ray ve travers bağlantıları bulunmaktadır. Travers bağlantısı üzerindeki vida Çizgi Yerel İkili Örüntü (ÇYİÖ) algoritması ile tespit edildikten sonra ORB yöntemi ile anahtar noktalar çıkarılmaktadır. Elde edilen anahtar noktalardan görsel kelime çantaları oluşturularak özellikler çıkarılmakta ve destek vektör makineler ile kusur sınıflandırması yapılmaktadır.

## 2. Ray Bağlantı Elemanı Kusur Tespiti İçin Önerilen Yaklaşım

Ray bağlantı elemanında oluşan kusur tespiti için görüntü işleme tabanlı bir yaklaşım önerilmiştir. Ray ile ilgili görüntüler genellikle trenin altından alındığı için ışıklandırmaları iyi değildir. Bu nedenle, ray görüntüleri gürültü içerir. Önerilen yaklaşımın ilk adımında, yüksek kontrastlı ray görüntüsünü elde etmek için görüntü netleştirme yöntemi uygulanmaktadır. Elde edilen görüntüde gürültü ve ışıklandırma etkileri giderilmektedir. Daha sonra elde edilen görüntüde ray ve travers bileşenlerinin konumu tespit edilmektedir. Elde edilen travers bileşeni üzerindeki bağlantı elemanının konumunu belirlemek için çizgi yerel ikili örüntü tekniği kullanılmıştır. Daha sonra tespit edilen bağlantı elemanı görüntüsü üzerinden ORB algoritması ile öz nitelikler çıkarılmakta ve destek vektör makinası ile sınıflandırılmaktadır. Önerilen yöntemin blok şeması Şekil 1'de verilmiştir.



Şekil 1. Önerilen sistemin blok şeması.

Şekil 1’de ilk olarak alınan ray görüntüsü üzerinde görüntü netleştirme işlemi yapılarak görüntüdeki gürültüler giderilmektedir. Ray ve travers konumları belirlendikten sonra ay bileşeni ÇYİÖ ile tespit edilip ORB algoritması ile özellikler çıkarılmaktadır. Elde edilen özellikler destek vektör makineler ile sınıflandırılarak kusur tespiti yapılmaktadır.

## 2.1. Görüntü Ön İşleme Adımı ve İyileştirme

Trenin altından elde edilen görüntülerin kontrast değeri düşük olduğundan ilk aşamada görüntü iyileştirme işlemi uygulanacaktır. Bir renkli görüntü R, G ve B olmak üzere üç bileşenden oluşur. Renkli görüntü gri görüntüye dönüştürülürken genelde 3 katsayı kullanılır. Bu katsayılar  $k_r$ ,  $k_b$  ve  $k_g$  olmak üzere değerleri genellikle  $k_r=0.2989$ ,  $k_g=0.5870$  ve  $k_b=0.1140$  olarak seçilir. Gri görüntüye dönüşüm için genellikle aşağıdaki dönüşüm kullanılır.

$$I(x, y) = k_r R(x, y) + k_b B(x, y) + k_g G(x, y) \quad (1)$$

Yüksek kontrastlı ve düşük homojenliğe sahip bir görüntüyü elde etmek için uygun katsayıların belirlenmesi gerekir [13]. Denklemde  $k_b$  değeri bu genellemeyi kaybetmeden 1 olarak seçilebilir. Düşük homojenliğe sahip bir görüntü elde etmek için varyansı yüksek olan bir monokrom görüntü oluşturulmalıdır. Önerilen sistemin algoritması Şekil 2’de verilmiştir.

function J=yuksekkontrasthesap(R,G,B)
1. Gri görüntüyü hesapla (Denklem 1) $I(x, y) = k_r R(x, y) + B(x, y) + k_g G(x, y)$
2. Varyansı hesapla $\sigma_f^2 = \text{variance}((I - I_{min}) / (I_{max} - I_{min}))$
3. En iyi parametreleri bul $(\hat{k}_r, \hat{k}_g) = \arg \max k_r, k_g (\sigma_f^2)$
4. Elde edilen parametrelerle yeni görüntüyü hesapla $\hat{I}(x, y) = \hat{k}_r R(x, y) + B(x, y) + \hat{k}_g G(x, y)$
5. Yüksek kontrastlı görüntüyü hesapla $J = (\hat{I} - \hat{I}_{min}) / (\hat{I}_{max} - \hat{I}_{min})$

Şekil 2. Yüksek kontrastlı görüntüyü hesaplama.

Şekil 2’de renkli görüntü gri görüntüye dönüştürülürken yüksek kontrastlı bir görüntü elde etmek için uygun katsayılarla hesaplanmaktadır. Bu katsayılar, standart sapmayı maksimum yapacak şekilde seçilmektedir. Bu amaçla Matlab’taki fminsearch metodu kullanılmıştır.

## 2.2. Ray ve Travers Lokalizasyonu

Ray ve travers konumunun bulunması için ilk olarak elde edilen yüksek kontrastlı görüntü ikili görüntüye dönüştürülür. Bu amaçla, Otsu yönteminden faydalanılmaktadır [14]. Daha sonra elde edilen görüntüden rayın ve

traverslerin konumu belirlenmektedir. İkili görüntüye dikey projeksiyonu elde etmek için aşağıdaki gibi bir ön işleme uygulanır.

$$P(j) = \sum_{i=1}^w S(i, j) \quad i=1, \dots, w, j=1 \dots h \quad (2)$$


Denklem 2'de  $S(i, j)$ , bölütlenen görüntünün piksel değerini göstermektedir. Bölütlenen görüntü 0 veya 1'lerden oluşan ikili bir görüntüdür. Daha sonra elde edilen sinyal  $P(j)$ 'nin ardışık farkları Denklem 3'teki gibi alınmaktadır.

$$DP(j) = P(i + 1) - P(i), i = 1, 2, \dots, w \quad (3)$$

Denklem 3'te elde edilen ardışık farklar sinyalinde en büyük iki değer rayın kenarlarını göstermektedir. Bu işlem travers tespiti için de yatay olarak uygulanmakta ve travers de tespit edilmektedir.

### 2.3. Çizgi Yerel İkili Örüntü(ÇYİÖ) Dayalı Bağlantı Elemanı Konum Tespiti

Orijinal yerel ikili örüntü yöntemi merkez piksel ile komşu pikselleri karşılaştırarak bir değer üretir. Eğer merkez piksel değeri  $p_c$  ve komşu bir piksel  $p_n$  olarak alınırsa  $p_n > p_c$  ise ilgili piksel 1, değilse 0 değerini alır [15]. Daha sonra merkez piksel etrafında her bitin ağırlıklı toplamı merkez pikselin değerini verir. Lokal ikili örüntü yöntemi Şekil 3'te verilmiştir.




Şekil 3. Bir görüntüdeki yerel ikili desen.

Şekil 3'te yerel ikili örüntü ile elde edilen görüntüde vidanın tespit edilmesi oldukça zordur. Bu yüzden bu çalışmada çizgi yerel ikili örüntü yöntemi kullanılmıştır. Bu yöntemin farkı çizgi yönünde bir karşılaştırma yapmasıdır [16]. Bu yöntem, Denklem 4'te verilmiştir.

$$LLBP = sign(p_{c-n} - p_c) \times sign(p_{c+n} - p_c) 2^0 \quad (4)$$

Denklem 4'te  $p_c$  ve  $P_{c \pm n}$  merkez piksel ve iki komşusunu göstermektedir. ÇYİÖ sadece  $n$  parametresine sahip olup bu parametre ne kadar büyük seçilirse vida o kadar geniş görünür. Küçük  $n$  değerleri çok fazla gürültü içerdiğinden vidanın belirlenmesi zordur. Şekil 4'te ÇYİÖ yöntemi ve farklı  $n$  parametreleri için uygulanması gösterilmiştir.



Şekil 4. ÇYİÖ yapısı ve farklı n değerleri için uygulaması.

Şekil 4'te gösterildiği gibi n değeri küçük seçildiğinde tamamen gürültülü bir görüntü elde edilmekte ve gürültülü piksel değerleri vidanın tespitini zorlaştırır. Buna karşın, n değeri büyük seçildiğinde gürültü azalmakta ve vida tespiti kolaylaşmaktadır. Travers üzerindeki vida belirlendikten sonra kenar noktaları görüntü kontörü çizilerek bulunur.

#### 2.4. ORB Tabanlı Özellik Çıkarımı ve Sınıflandırma

ORB algoritması, 2011 yılında Ethan Rublee ve ark. tarafından SIFT ve SURF algoritmalarına alternatif olarak geliştirilmiştir [17]. ORB, bir görüntüde özel bölgeler bularak başlar. Bu noktalara kilit noktalar denir. Kilit noktalar, bir görüntüde bulunan oldukça belirgin konumlardır. Piksel değerlerinin keskin bir şekilde değiştiği noktalar kilit nokta olabilir. ORB, performansı iyileştirmek için bazı ek özellikler içeren FAST ve BRIEF algoritmasının bir birleşimidir. Bu iki teknik iyi performansa ve uygun maliyete sahiptir. Bu nedenle ORB, özellik bulmada SIFT kadar iyiyken, hız olarak ise daha hızlıdır [15]. Bu nedenle, gerçek zamanlı uygulamalarda sıklıkla kullanılmaktadır. ORB algoritmasında, FAST algoritması yardımıyla anahtar noktalar tespit edilir. Ardından anahtar noktaların yönelimleri bulunur. Son olarak yönlendirilmiş BRIEF tanımlayıcıları oluşturulur.

FAST algoritmasında ilk olarak yoğunluğu I olan bir p pikseli belirlenir. Bu pikseller aday bir pikselin köşe olup olmadığını belirler.

$$N = \sum_{x \in \text{circle}(p)} f(I(p), I(x)) \quad (5)$$

Denklem 5'teki f fonksiyonu aşağıdaki gibi hesaplanır.

$$f = \begin{cases} 1, & |I(x) - I(p)| > \epsilon_d \\ 0, & \text{diğer} \end{cases} \quad (6)$$

I(p) çemberdeki merkez pikseli gösterir. I(x) ise çemberdeki herhangi bir noktayı ifade eder. Eğer iki noktanın mutlak farkı  $\epsilon_d$  değerinden büyük ise 1, değilse 0 değerini alır. Yukarıdaki denklem ile verilen bir eşik değerinden daha büyük olan piksel sayısı olan N değeri hesaplanır. FAST, oryantasyonu hesaplamadığı için ORB, oryantasyon telafisi için Denklem 4'teki değişikliği yapmıştır. Verilen görüntünün I(x,y) parçası için, moment değerleri Denklem 7'deki gibi bulunur.

$$m_{pq} = \sum_{x,y} x^p x^q I(x, y) \quad (7)$$

Denklem 7'deki momentten parçanın C merkezi aşağıdaki gibi hesaplanır.

$$C = \left( \frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (8)$$

Parçanın yönü  $\theta$ , Denklem 9'daki gibi bulunur.

$$\theta = \arctan(m_{01}, m_{10}) \quad (9)$$


ORB algoritmasının ikinci kısmında ise FAST algoritması tarafından bulunan kilit noktaları alınır ve bunlar birlikte bir nesneyi temsil edebilen özellik vektörlerine dönüştürülür. ORB, öznelik vektörleri oluşturmak için BRIEF algoritmasını kullanır. BRIEF algoritması, bir ikili özellik tanımlayıcısıdır ve ikili dizeleri doğrudan bulmak için bir kısa yol sağlar. İkili bir tanımlayıcı oluştururken, yalnızca algılanan noktaların çevresinde bulunan iki piksel konumu arasındaki yoğunluğu karşılaştırmak gerekir. Bu işlem de düşük maliyetli olmasını sağlar. BRIEF, ön işlem olarak yumuşatılmış bir görüntü parçası alır ve benzersiz bir şekilde bir dizi (x, y) konum çifti seçer. Daha sonra bu konum çiftlerinde bazı piksel yoğunluğu karşılaştırmaları yapılır. P(x), x noktasındaki P'nin yoğunluğu ve P (y), y noktasındaki P'nin yoğunluğu olmak üzere Denklem 10'da gösterilmiştir.

$$\tau(p; x, y) = \begin{cases} 1, p(x) < p(y) \\ 0, p(x) \geq p(y) \end{cases} \quad (10)$$

Özellik vektörü  $fn(p)$  Denklem 11'deki gibi n adet ikili test yapılarak oluşturulur.

$$f_n(p) = \sum_{1 \leq i \leq n} 2^{i-1} \tau(p; x, y) \quad (11)$$

ORB'de anahtar noktaların yön bilgisi ile BRIEF sonuçları ilişkilendirilir ve yönlendirilmiş BRIEF tanımlayıcıları oluşturulur. ORB algoritması ile çıkarılan özellikler, Bag of visual words (BOVW) için kullanılmıştır. Bag of words (BOW) kavramı ilk olarak metin belge analizi için metin erişim alanı probleminde önerilmiş ve daha sonra bilgisayarla görme uygulamaları için Bag of visual Words (BOVW) adıyla uyarlanmıştır [17]. Yani, metin belgeleri yerine görüntüleri sınıflandırmak için BOW modeli genişletilmiştir. Görüntü analizi için, renk, doku gibi yerel bölgelerin veya noktaların düşük seviyeli görsel özelliklerini kümeleyerek vektör niceleme sürecine dayanan BOVW modelinde bir kelimenin görsel bir analogu kullanılır. Görüntülerden kelime çantası elde etmek için ilk olarak görüntüden özellik çıkarımı yapılmalıdır. Özellik çıkarımı SIFT, SURF, ORB gibi algoritmalar ile yapılabilir. Bu çalışmada, yukarıda belirtildiği gibi ORB algoritması kullanılmıştır. ORB algoritması uygulanan görüntü, Görsel kelime çantası modeli ile özellik çıkarımı ve destek vektör makinası ile sınıflandırma aşamaları ile Şekil 5'te verilmiştir.



Şekil 5. Kelime çantası modeli akış diyagramı.

Şekil 5'te elde edilen bu görsel kelimelerin farklı özellikleri vardır. Bu nedenle, aynı şeyi temsil eden görselleri bir araya toplamak için bazı kümeleme yöntemlerine ihtiyacımız vardır. Bu işlem için tanımlayıcılardan kümeler oluşturulur. Son olarak, her bir görüntü için frekans histogramı oluşturulur. Bu histogramlar görsel kelime çantasını oluşturmaktadır. Son aşamada Destek Vektör Makinesi (DVM) ile histogramlar kullanılarak tahmin işlemi yapılacaktır. Performans ölçümü için karmaşıklık matrisi kullanılmaktadır. Karmaşıklık matrisi, çıktının iki veya daha fazla sınıf olabileceği makine öğrenimi sınıflandırma problemleri için bir performans ölçümüdür. Tahmini değerler ve gerçek değerlerin 4 farklı kombinasyonunu içeren bir matris olup iki sınıf için Şekil 6'da karmaşıklık matrisinin yapısı verilmiştir.

		Gerçek sınıf	
		Pozitif	Negatif
Tahmin edilen sınıf	Pozitif	DP	YP
	Negatif	YN	DN

Şekil 6. Karmaşıklık matrisi yapısı.

Karmaşıklık matrisinin içeriği şu şekildedir: DP (Doğru Pozitif) ve DN (Doğru Negatif) modelin doğru olarak tahmin edildiği alanlardır. YP (Yanlış Pozitif) ve YN (Yanlış Negatif) ise modelin yanlış olarak tahmin edildiği alanlardır. Karmaşıklık matrisi; Duyarlılık, Kesinlik ve F1 değerlerini ölçmek için son derece kullanışlıdır. Duyarlılık, pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin edildiğini gösteren bir metriktir. Kesinlik, pozitif olarak tahmin edilen değerlerin gerçekten kaç adetinin pozitif olduğunu gösteren bir orandır. F1 değeri bize Kesinlik ve Duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Basit bir ortalama yerine harmonik ortalama olmasının sebebi ise uç durumların da göz önüne alınması gerektiği içindir. Bu değerleri hesaplamak için gerekli denklemler aşağıda sırasıyla verilmiştir.


$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (12)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (13)$$

$$F1 = \frac{2 * \text{Geri}_\text{çağırma} * \text{Kesinlik}}{\text{Geri}_\text{çağırma} + \text{Kesinlik}} \quad (14)$$

### 3. Deneysel Sonuçlar

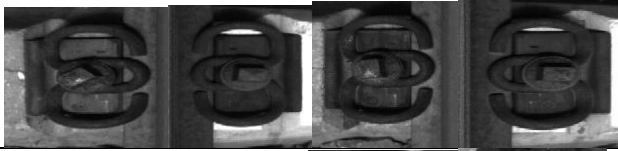
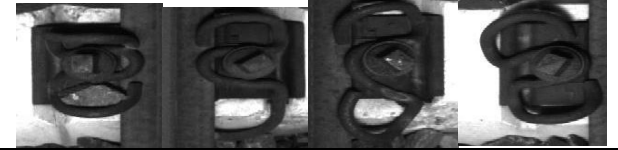
Çalışmada kullanılan verileri elde etmek için Türkiye Cumhuriyeti Devlet Demiryolları Araştırma Merkezi (DATEM) tarafından bir ölçüm treni üzerinden veriler elde edilmiştir. Şekil 7'de verilerin elde edildiği ölçüm sistemi gösterilmiştir.




Şekil 7. Ölçüm Sistemi.

Eğitim deneyinde veri seti olarak sağlam ve kusurlu olmak üzere 2 farklı durumu gösteren görüntü kümesi kullanılmıştır. Kullanılan veri seti 144 sağlam, 55 deforme bağlantı elemanı içermektedir. Bu çalışmada kullanılan bazı sağlam ve deforme bağlantı elemanı örnekleri Tablo 1'de gösterilmiştir.

Tablo 1. Kullanılan veri setinden sağlam ve deforme vida örnekleri.

Sınıf	Örnek görüntüler	Örnek sayısı
Sağlam		144
Kusurlu		55


Tablo 1'de gösterildiği gibi deforme olan vidalarda dönme, eğilme veya kopma gibi kusurlar oluşmaktadır. Bu veri kümesi oluşturulurken görüntüler trenin altından alındığı için rayın diğer kısımları da görülmektedir. Bu yüzden vidanın konumunu bulmak için alınan görüntülere ilk olarak görüntü iyileştirme işlemi uygulanmaktadır. Şekil 8'de bu ön işleme adımı gösterilmiştir.



(a) Orijinal Görüntü (b) Görüntü netleştirme sonucu  
Şekil 8. Orijinal görüntü ve yüksek kontrastlı görüntü sonucu.


Şekil 8'de gösterildiği gibi görüntü netleştirme uygulandıktan sonra ray ve travers bileşenlerinin daha net ortaya çıktığı görülmektedir. Görüntü netleştirme işleminden sonra elde edilen görüntüden ray ve travers konumu belirlenir. Ray konumu için Denklem 3'te verilen hesaplama yapılır ve en büyük değer rayın konumunu verir. Şekil 9(a)'da yatay projeksiyon algoritmasının sonucu verilmiştir. Şekil 9(a)'da ray konumu için çalıştırılan yatay projeksiyon algoritması dikeyde de çalıştırılarak travers sınırları Şekil 9(b)'deki gibi tespit edilmektedir.





Şekil 9. Ray ve Travers konumunun tespiti.

Şekil 10'da travers ve ray tespit edildikten sonra ilgili alan kırılarak ÇYİÖ algoritması uygulanmaktadır. Burada bölütleme tabanlı bir yöntem seçilmemiştir. Çünkü bölütleme yapıldığında karanlık olan bölgelerde yanlış bölütleme yapılabilmektedir. Vidanın tam konumunu belirlemek zorlaşmaktadır. ÇYİÖ algoritması uygulandıktan sonra kontur çizgileri ile vidanın tam konumu belirlenmektedir. ÇYİÖ algoritması ve kontur sonucu Şekil 10'da verilmiştir.



Şekil 10. ÇYİÖ uygulaması ve vida tespiti.

Şekil 10 (a)'da ilk olarak ÇYİÖ algoritması uygulanarak vidanın olduğu görüntü elde edilmektedir. Fakat burada bazı gürültülü pikseller oluşmaktadır. Bu pikselleri yok etmek için erozyon, açma ve kapama gibi morfolojik işlemler uygulanmaktadır. Vidanın konumu tespit edildikten sonra vidalarda olan kusurların belirlenmesi gerekir. Verilere ilk olarak ORB anahtar nokta çıkarma algoritması uygulanmıştır. Ardından eğitim görüntülerinin tanımlayıcıları listeye eklenmiştir. Tanımlayıcılarda K-means kullanılarak kümeleme yapılmıştır. Kümeleme işlemi için  $k$  değeri 200 seçilmiştir. Bu işlemden sonra eğitim görüntülerinin histogramları oluşturulup standardizasyon işlemi uygulanmıştır. Son olarak destek vektör makinesi (DVM) ile sınıflandırma modeli oluşturulmuştur. ORB tabanlı görsel kelime çantası modeline dayalı bağlantı elemanı kontrol uygulamasının karmaşıklık matrisi sonucu Şekil 11(a)'da verilmiştir. Önerilen yöntem aynı veri kümesi üzerinde SURF ve HOG anahtar nokta çıkarım tekniği kullanılarak da test edilmiştir. Karmaşıklık matrisleri Şekil 11(b) ve (c)'de verilmiştir.

		Tahmin edilen sınıf	
		Sağlam	Kusurlu
Doğru sınıf	Sağlam	140	3
	Kusurlu	4	52

(a) ORB tabanlı özellik çıkarımı

		Tahmin edilen sınıf	
		Sağlam	Kusurlu
Doğru sınıf	Sağlam	139	12
	Kusurlu	4	43

(b) SURF tabanlı özellik çıkarımı

		Tahmin edilen sınıf	
		Sağlam	Kusurlu
Doğru sınıf	Sağlam	125	18
	Kusurlu	9	46

(c) HOG tabanlı özellik çıkarımı

Şekil 11. Farklı özellik çıkarım yöntemlerine göre başarımlar.

Bu çalışmada, yüksek doğruluk oranı ile bağlantı elemanı kusur tespiti üzerinde çalışılmıştır. Karmaşıklık matrisini elde etmek için 5 noktalı çapraz doğrulama kullanılmıştır. ORB yönteminde hatalı tespit edilen örnek sayısı oldukça düşüktür. Sonuç olarak önerilen yöntemin yüksek doğruluk oranında sonuçlar verdiği gösterilmiştir. Şekil 11(b)'de sınıflandırma yöntemi, K-Means küme sayısı ve eğitim örneği sayısı aynı seçilerek SURF tabanlı algoritma çalıştırılarak bu sonuçlar elde edilmiştir. Ardından HOG tabanlı yöntem için de deneme yapılmıştır. Üç yöntemin performans ölçütlerine göre karşılaştırma sonuçları Tablo 2'de verilmiştir.

**Tablo 2.** Beş ayrı ölçüt için ORB, SURF ve HOG performans değerleri.

Ölçüt (%)	ORB	SURF	HOG
Doğruluk	<b>96.48</b>	91.92	86.36
Geri çağırma	<b>97.22</b>	97.20	93.28
Kesinlik	<b>97.90</b>	92.05	87.41
F-1	<b>97.56</b>	94.56	90.25
Özellik sayısı	<b>1000</b>	129792	71604

Tablo 2’de görüldüğü üzere ORB tabanlı yöntem diğer yöntemlere göre bütün ölçütlerde daha iyi performans göstermektedir. Ayrıca ORB yöntemi ile elde edilen özellik sayısı oldukça düşüktür. Sınıflandırma için destek vektör makineler kullanılmıştır. Destek vektör makinasının çekirdek fonksiyonu olarak radyal tabanlı model önerilmiştir. Literatürde farklı özellik çıkarım yöntemleri ve sınıflandırma metotları kullanılarak çok sayıda çalışma bulunmaktadır. Bu çalışmada önerilen yöntemin performansı, literatürde önerilen farkı yaklaşımlar ile karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 3’te verilmiştir.

**Tablo 3.** Literatürde bulunan diğer yaklaşımlar ile karşılaştırma.

Referans	Özellik Çıkarımı	Sınıf Sayısı	Veri Boyutu	Sınıflandırma Metodu	Doğruluk (%)
[9]	Histogram tepe noktası kontrolü	2	745	Temel bileşen analizi ve derinlik tepe yöntemi	92.91
[11]	Yönlendirilmiş gradyanların histogramı (HOG)	3	6445	Bulanık kümeleme ve eşikleme	95.50
[12]	Histogram Eşitleme	2	584	Evrişimsel sinir ağı	95.20
[16]	Local ikili örüntü (LBP)	3	6000	Destek vektör makinası	93.38
[18]	Normalize edilmiş çapraz korelasyon	2	195	Geometrik Düzenleme indeksi	89.23
<b>Önerilen Yöntem</b>	<b>Yüksek kontrastlı görüntü, ORB ve ÇYİÖ</b>	<b>2</b>	<b>199</b>	<b>Destek vektör makinası</b>	<b>96.48</b>

Tablo 3’te literatürde yapılan çalışmalar ile karşılaştırıldığında verilen veri seti için önerilen yöntemin yüksek bir doğruluk elde ettiği görülmektedir. Diğer çalışmalarda kullanılan veri kümeleri yazarlar tarafından paylaşılmadığı için bu veri kümeleri ile testler yapılmamıştır. Fakat bütün veri kümelerinde kullanılan veri kümeleri aynı tür vidalara aittir. [9] nolu çalışmada histogram tepe noktası benzerlik algoritması kullanılmıştır. Fakat çalışmanın doğruluk ve diğer değerleri düşük çıkmıştır. Yönlendirilmiş gradyan histogramı ve bulanık küme kullanan yöntem farklı ışıklandırma durumlarında kusurları belirlemesine rağmen bağlantı elemanının bu ışıklandırma koşullarında nasıl tespit edildiği belirsizdir [11]. Histogram eşitleme kullanan yöntemin temel amacı bölütleme tabanlı bir yöntem ile kusurları belirlemektir [12]. Elde edilen alt graflar evrişimsel sinir ağı ile eğitilerek kusurlar belirlenmiştir. Bağlantı elemanı tespiti için lokal ikili örüntü kullanan çalışmada filtre boyutlarının hassas ayarlanması gerekmektedir [16]. Normaliz edilmiş çapraz korelasyon ile bağlantı elemanı tespit edilmiş ve kusurlar geometrik düzenleme indeksi ile tespit edilmiştir [18]. Çalışmada kullanılan tespit yöntemi bağlantı elemanını doğru bir şekilde tespit etmesine rağmen kusur belirleme yönteminin başarımı düşük kalmıştır. Önerilen yöntem ise hem bağlantı elemanı tespiti hem de kusur tespitinde önemli bir katkı sunmaktadır. Işıklıdırma ile ilgili problemler yüksek kontrastlı görüntü ile elde edildiğinden bağlantı elemanının konumu daha kolay belirlenmektedir. Ayrıca ORB yöntemi diğer özellik çıkarım tekniklerine göre hem daha hızlı hem de daha iyi sonuçlar vermektedir.

#### 4. Sonuçlar

Bu çalışmada, demiryollarında vidaların tespiti ve bu vidalarda oluşan kusurların tespiti için ORB tabanlı bir yöntem önerilmiştir. Önerilen yöntem ilk olarak görüntü işleme ve ön işleme yöntemleri ile ray ve travers konumunu belirlemektedir. Daha sonra vidanın konumu ÇYİÖ algoritması ile tespit edilmektedir. Tespit edilen vida görüntülerine ORB yöntemi uygulanarak anahtar noktalar ve özellikler belirlenmekte daha sonra bu özellikler BOVW yöntemi için kullanılmıştır. Bu özellikler, destek vektör makinalara verilerek kusurlu veya sağlam olarak

sınıflandırılmaktadır. Deneylede kullanılan veri kümesi gerçek bir ölçüm treninden alınmıştır. Bu amaçla 144 sağlam ve 55 kusurlu vida olmak üzere 199 görüntüden oluşan bir veri kümesi üzerinde testler yapılmıştır. Uygulama sonucunda kusur tespit doğruluğu %96.88 olarak elde edilmiştir. Önerilen yöntemin sunduğu temel katkılar aşağıdaki gibi sıralanabilir:

- Görüntü ön işleme adımındaki iyileştirme ile ray ve travers tespitinin daha kolay yapılabilmesi,
- ÇYİÖ algoritmasının travers üzerinde uygulanması ile vida tespitinin daha doğru bir şekilde yapılması,
- ORB algoritması anahtar nokta belirlemede daha hızlı olduğundan gerçek zamanlı uygulaması kolaydır.

### Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TUBITAK) tarafından 120E097 no'lu proje ile desteklenmiştir.

### Kaynaklar

- [1] Peng, Z., Wang, C., Ma, Z., & Liu, H. (2019). A Multifeature Hierarchical Locating Algorithm for Hexagon Nut of Railway Fasteners. *IEEE Transactions on Instrumentation and Measurement*, 69(3), 693-699.
- [2] Utrata, D., & Clark, R. (2003, March). Groundwork for rail flaw detection using ultrasonic phased array inspection. In *AIP Conference Proceedings* (Vol. 657, No. 1, pp. 799-805). American Institute of Physics.
- [3] Chen, Q., Niu, X., Zuo, L., Zhang, T., Xiao, F., Liu, Y., & Liu, J. (2018). A railway track geometry measuring trolley system based on aided INS. *Sensors*, 18(2), 538.
- [4] Gan, J., Wang, J., Yu, H., Li, Q., & Shi, Z. (2018). Online rail surface inspection utilizing spatial consistency and continuity. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*.
- [5] Zhang, H., Jin, X., Wu, Q. J., Wang, Y., He, Z., & Yang, Y. (2018). Automatic visual detection system of railway surface defects with curvature filter and improved Gaussian mixture model. *IEEE Transactions on Instrumentation and Measurement*, 67(7), 1593-1608.
- [6] Gibert, X., Patel, V. M., & Chellappa, R. (2016). Deep multitask learning for railway track inspection. *IEEE transactions on intelligent transportation systems*, 18(1), 153-164.
- [7] 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.
- [8] 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.
- [9] Aytakin, Ç., Rezaeitabar, Y., Dogru, S., & Ulusoy, I. (2015). Railway fastener inspection by real-time machine vision. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 45(7), 1101-1107.
- [10] Wei, X., Yang, Z., Liu, Y., Wei, D., Jia, L., & Li, Y. (2019). Railway track fastener defect detection based on image processing and deep learning techniques: A comparative study. *Engineering Applications of Artificial Intelligence*, 80, 66-81.
- [11] He, B., Luo, J., Ou, Y., Xiong, Y., & Li, B. (2020). Railway Fastener Defects Detection under Various Illumination Conditions using Fuzzy C-Means Part Model. *Transportation Research Record*, 0361198120977182.
- [12] Ma, A., Lv, Z., Chen, X., Li, L., Qiu, Y., Zheng, S., & Chai, X. (2020). Pandrol track fastener defect detection based on local convolutional neural networks. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 0959651820953679.
- [13] Mery, D., & Pedreschi, F. (2005). Segmentation of colour food images using a robust algorithm. *Journal of Food engineering*, 66(3), 353-360.
- [14] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- [15] Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, 24(7), 971-987.
- [16] Fan, H., Cosman, P. C., Hou, Y., & Li, B. (2018). High-speed railway fastener detection based on a line local binary pattern. *IEEE Signal Processing Letters*, 25(6), 788-792.
- [17] Csurka, G., Dance, C., Fan, L., Willamowski, J., & Bray, C. (2004, May). Visual categorization with bags of keypoints. In *Workshop on statistical learning in computer vision, ECCV* (Vol. 1, No. 1-22, pp. 1-2).
- [18] Taheri, N., Nejad, F. M., & Zakeri, H. (2019). A Brief Overview and New Knowledge Based System for Rail Direct Fastening Evaluation Using Digital Image Processing. *Archives of Computational Methods in Engineering*, 1-19.