



# Ray Bileşenlerinde Meydana Gelen Arızaların Görüntü İşleme Teknikleri ile Tespit Edilmesi

*Araştırma Makalesi/Research Article*

 Cüneyt ÖZDEMİR<sup>1</sup>,  Yılmaz KAYA<sup>2</sup>

<sup>1</sup>TBMYO, Siirt Üniversitesi, Siirt, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği, Siirt Üniversitesi, Siirt, Türkiye

[cozdemir@siirt.edu.tr](mailto:cozdemir@siirt.edu.tr), [yilmazkaya@siirt.edu.tr](mailto:yilmazkaya@siirt.edu.tr)

(Geliş/Received:02.07.2020; Kabul/Accepted:25.01.2021)

DOI: 10.17671/gazibtd.762853

**Özet**— Bu çalışmada görüntü işleme teknikleri kullanılarak demiryollarında kullanılan ray, bağlantı noktaları, travers gibi bileşenlerde oluşan kusurların ve hataların tespiti gerçekleştirilmiştir. Demiryolu bileşenlerinde oluşan hataların erken tespiti yapılarak, bu hataların hızlı ve etkin bir şekilde ortadan kaldırılması ve bu hatalardan dolayı oluşabilecek kazaların ve kayıpların önüne geçilmesi amaçlanmıştır. Bu kapsamda demiryolu bileşenlerinden olan ray görüntülerinden bağlantı noktasında vidası olmayan, sıkma aparatı dönmüş veya çıkmış olan, ray çatlakları ve travers çatlakları bulunan görüntülerden oluşan 4 farklı bileşenden 7 farklı problem tespit edilerek çalışma gerçekleştirilmiştir. Elde edilen görüntülerden öncelikle SIFT, SURF, GLCM, LBP ve HOG olmak üzere 5 farklı öznelik çıkarım yöntemi kullanılarak öznelikler elde edilmiştir. Daha sonra elde edilen öznelik vektörleri kullanılarak Decision Tree (DT), Gradient Boosting Classifier (GBC), Linear Discriminant Analysis (LDA), SVM, SVC, Logistic Regression (LR), Naive Bayes (NB), Nearest Neighbors(Knn), Neural Net (NN) ve Random Forest(RF) gibi 10 farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. HOG kullanılarak çıkarılan özneliklerden SVM sınıflandırma yöntemi ile %98 oranında başarı gözlenmiştir.

**Anahtar Kelimeler**— demir yolları, çatlak-kırık raylar, surf, sift, glcm, hog, lbp

## Detection of Faults in Rail Components with Image Processing Techniques

**Abstract**— In this study, image processing method were utilized for the early detection of defects and faults in the rails used on the railways and the components around these rails. Through early detection of the failures occurring in the railway components, this study aims to remove these failures rapidly and in an effective way; and prevent probable accidents and losses that may occur. In this context, seven particular problems have been identified from four diverse components comprised of the images that no screw situated at the junction point, clamping device rotated or extracted, rail and traverse cracks exist. From the images obtained, the features were obtained by using 5 different feature extraction methods: SIFT, SURF, GLCM, LBP and HOG. Then, using the feature vectors, Classification procedures were carried out with 10 different machine learning methods such as Decision Tree (DT), Gradient Boosting Classifier (GBC), Linear Discriminant Analysis (LDA), SVM, SVC, Logistic Regression (LR), Naive Bayes (NB), Nearest Neighbors (Knn), Neural Net (NN) and Random Forest (RF). 98% success was observed with the SVM classification method, which is one of the features extracted using HOG.

**Keywords**— Railways, cracked-broken rails, surf, sift, glcm, hog, lbp

## 1. GİRİŞ (INTRODUCTION)

Demiryolları; ulaşım araçları arasında önemli bir yer tutar. Ucuz, güvenli ve konforlu olmasından dolayı çok tercih edilen ve yaygın kullanılan ulaşım araçlarından biridir. Demiryolları yük ve yolcu taşımacılığında önemli bir yer tutmaktadır. Yük taşımacılığı ile ekonomiye çok önemli katkı sağlarken, yolcu taşımacılığı ile güvenli, konforlu ve hızlı toplu taşıma aracı olarak kullanılmaktadır.

Demiryolu sistemlerinde hataların tespiti ve bu hataların onarılması hayati öneme sahiptir. Demiryolu sistemlerinde meydana gelebilecek hatalar telafisi güç sonuçlara yol açabilir. Demiryolları ulaşımını sürdürmek için ulaşım araçlarının planlı ve düzenli bakımının yapılması gerekir. Demiryolu bileşenlerinde farklı sebeplerden dolayı çatlama, kırılma, travers çatlakları, ray yüzey çatlakları vb problemler oluşmaktadır. Son on yılda, ABD'deki demiryolu kazalarının yaklaşık üçte biri demiryolu parçalarına bağlı kusurlardan kaynaklanmıştır [1]. Demir yollarında oluşan bu problemlerin erken tespiti ve zamanında onarımı çok önemlidir. Aksi takdirde telafisi imkânsız sonuçlara sebep olabilir.

Raylı ulaşım sistemlerinin en kritik bileşenlerinden biri demir ray hatlarıdır. Ray hatlarının yoğun kullanımı, bu raylar üzerine düşen ağırlık, yüksek hız, aks yükleri, çevresel ve fiziksel koşullar ile birlikte bu bileşenlerin bozulmasına ve arıza çıkarmasına neden olmaktadır. Bu bileşenlerde oluşan arızalardan kaynaklı ölümcül kazalar olabilmektedir. Bu nedenle bu bileşenlerin periyodik bakımının yapılması gerekir [2]. Bunun yanında kırılmış raylar veya raylarda oluşan küçük bir kusurun dahi bulunması, büyük bakım maliyetlerine yol açabilecek, sistemin güvenilirliğini ve kullanılabilirliğini azaltabilir [3,4]. Bu hataların tespiti demiryolu teknolojisinin güvenilirliği ve gelişimi açısından çok önemlidir. Bu hataların tespiti ve onarımı için demiryolunun düzenli olarak gözlemlenmesi ve tespit edilen hataların onarılması gerekmektedir [5,6]. Demiryollarında demiryolu izleme bakım faaliyetlerinde temaslı ve temassız 2 farklı yöntem uygulanmaktadır. Temaslı yöntem verimsiz ve çok fazla iş gücü maliyeti gerektirir. Temassız yöntemlerde arızaların tespit edilmesi daha az maliyetli ve daha hızlı bir şekilde yapılır.

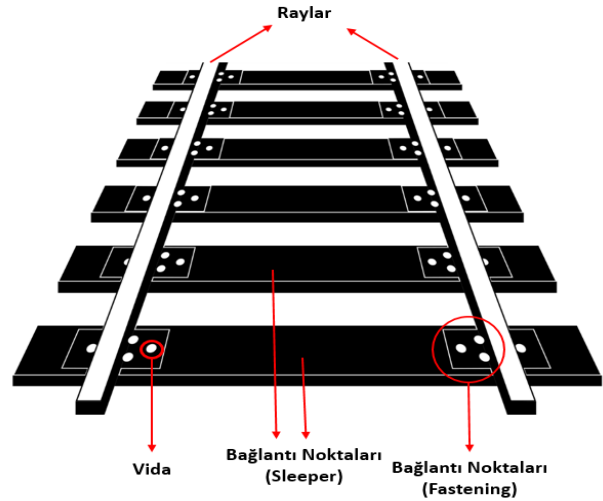
Bu çalışmada demiryolu bileşenlerinde bulunan arızaların tespiti için görüntü işleme yöntemleri kullanılmıştır. Görüntü iyileştirme bir görüntüde oluşan bozulmaları ortadan kaldırmak için kullanılır [7]. Bu amaç kapsamında görüntülerin hangi sınıfa ait olduklarının yapılması için görüntülerin özniteliklerinin çıkarılması gerekmektedir. Görüntülerden öznitelik çıkarımı için GLCM, LBP, SURF ve SIFT yöntemleri kullanılmıştır. Elde edilen özniteliklerden görüntülerin arızalara göre sınıflandırılması için Decision Tree (DT), Gradient Boosting Classifier (GBC), Linear Discriminant Analysis (LDA), SVM, SVC, Logistic Regression (LR), Naive Bayes (NB), Nearest Neighbors(Knn), Neural Net (NN) ve Random Forest(RF) sınıflandırma algoritmaları

kullanılmıştır. Bu çalışmada beş farklı öznitelik çıkarım yöntemi ve 10 farklı sınıflandırma algoritması kullanılmıştır.

Rubel Biswas ve diğ. [8], Harris - Stephen'in ray parça görüntülerinde eksik bağlantı elemanlarının tespiti için karar destek makinaları(Support vector Machine, SVM) sınıflandırma metodunu kullanmışlardır. Bu çalışmada önerdikleri algoritmaları için % 81,25 sınıflandırma başarısı elde etmişlerdir. Bir diğer çalışmada Jiajia Liu ve diğ.[9], problemlili bağlantı elemanları içeren ve içermeyen verileri SVM sınıflandırma algoritması ile % 87.3 oranında doğru sınıflandırmışlardır. Karakose ve diğ.[10], görüntü işleme tabanlı bir yöntem geliştirerek ray yüzeyinde oluşan çatlakların tespit edilmesi için farklı açılardan yerleştirilmiş iki kameradan görüntüler elde etmişlerdir. Alınan görüntüler bir eşik değere göre sınıflandırılmıştır. %87.6 başarı oranı yakalanmıştır. Y. Xia ve diğ. [11] yaptıkları çalışmada ray görüntülerinden bağlantı elemanı bölgelerini tespit etmek için şablon eşleştirme yöntemi kullanılmıştır. Bağlantı elemanlarından çıkarılan Haar benzerlik öznitelikler ile AdaBoost algoritmasına girdiler verilir. Adabost algoritması ile %93.7 başarı oranı elde edilmiştir.

## 2. VERİ SETİ (DATA SETS)

Demiryolu bileşenlerine ait görüntüler Şekil 1'de gösterilmiştir. Demiryolu bileşenleri; bağlantı elemanları, raylar, vida ve traverslerden oluşmaktadır.



Şekil 1. Demiryolu bileşenleri (Railway components)

Bu çalışmada raylı sistemlerde kullanılan bileşenler arasında en çok kazalara ve problemlere sebebiyet veren 4 farklı demiryolu bileşeni üzerinde çalışmalar yapılmıştır. En çok karşılaşılan demiryolu bileşenlerine ait oluşan hatalar 7 farklı sınıfa ayrılarak, oluşan problemler tespit edilmeye çalışılmıştır. Bu problemler Şekil 2'de gösterilmiştir.

Demir raylarında oluşan çatlak ve kırıklar (Kırık\_Ray sınıfı) Şekil 2 (A)'da verilmiştir.

Demir raylarının bağlantısını sağlayan bağlantı noktalarında (fastening) bulunan vidaların çıkması, vidaların olmaması ve bundan kaynaklı olarak bağlantı noktalarının işlevsiz kalması. Sol\_Vida ve Sag\_Vida olarak sınıflandırılmıştır. Vida örnek görüntüler Şekil 2(B)'de gösterilmiştir.

Ray bağlantı sisteminde bulunan sıkma aparatlarının dönmesi, kırılması veya olmaması (Fastening). Sol\_Aparat ve Sag\_Aparat olarak sınıflandırılmıştır. Bu arıza türüne ait görüntüler Şekil 2 (C)'de verilmiştir.

İki ray yolunu doğrusal olarak birbirine bağlayan bağlantı noktası (Travers) yüzeylerinde oluşan çatlaklar, kırıklar (Sleeper). Sol\_Baglanti ve Sag\_Baglanti olarak sınıflandırılmıştır. Bu arıza türüne ait görüntüler Şekil 2 (D)'de verilmiştir.

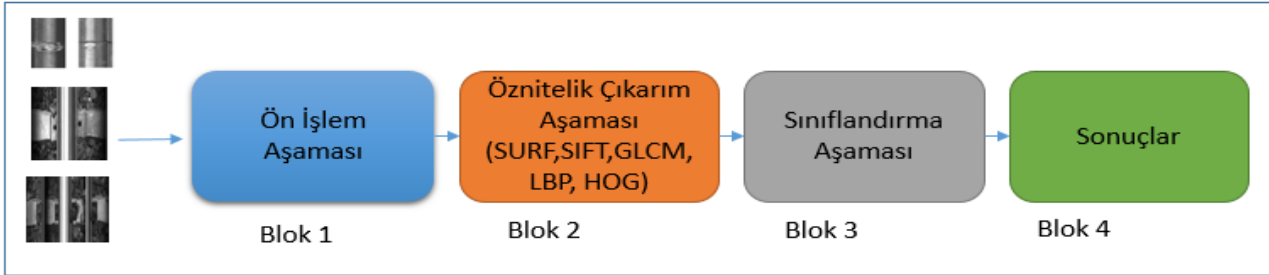


Şekil 2. Arızalara ait örnek görüntüler (Sample images of faults)

### 3. METOT (METHOD)

#### 3.1. Önerilen Ray Arıza Tespit Sistemi (Recommended Rail Fault Detection System)

Bu çalışmada ray hatalarının tespiti için önerilen sistem aşağıdaki aşamalardan oluşmaktadır. Arıza tespit yöntemine ait diyagram Şekil 3'de gösterilmiştir.



Şekil 3: Ray arıza tespit diyagramı (Rail fault detection diagram)

Her aşamada gerçekleştirilen işlemler kısaca özetlemek olursa:

Blok 1: Bu aşamada görüntüler üzerinde temizleme işlemleri gerçekleştirilmiştir.

Blok 2: Öznitelik çıkarım aşamasıdır. Bu aşamada SIFT, SURF, GLCM, LBP ve HOG ile öznitelikler elde edilmiştir. Bu öznitelikler sınıflandırma metotlarına giriş olarak verilecektir.

Blok 3: Sınıflandırma aşamasıdır. Elde edilen öznitelik vektörleri kullanılarak ray hataları tespit esilmektedir. Sınıflandırma işlemleri Decision Tree (DT), Gradient Boosting Classifier (GBC), Linear Discriminant Analysis (LDA), SVM, SVC, Logistic Regression (LR), Naive Bayes (NB), Nearest Neighbors(Knn), Neural Net (NN) ve Random Forest(RF) yöntemleri ile 10 katlı çapraz geçerlilik testine göre gerçekleştirilmiştir.

Blok 4: Karar aşamasıdır. Sınıflandırma metotlarının çıktılarını belirtir.

#### 3.2. Öznitelik Çıkarım Yöntemleri (Attribute Extraction Methods)

Bu aşamada SIFT, SURF, LBP, GLCM ve HOG yöntemleri açıklanmıştır.

##### 3.2.1 Ölçekten bağımsız öznitelik dönüşümü (Scale invariant feature transform)

Nesnelerin ilgi noktalarının tespitini yapan bir yöntemdir. SIFT algoritmasında temel olarak izlenen 3 adım vardır [12,13] :

### a. Ölçeksel uzaydaki uç değer noktaların tespiti

Ölçeksel uzayda sabit olan noktalar. Nesnenin farklı durumlarda tanınmasını sağlar. Görüntü üzerinde nesne ile ilgili birçok nokta tespiti yapılır, farklı ölçek değerlerinde değişmeyen öznelikleri tespit etmek için Gauss filtreleme fonksiyonu (Eşitlik 1) uygulanır. Bu işlemin ardından elde edilen görüntü ile konvolüsyon yapılarak (Eşitlik 2)'deki gibi ölçek uzay fonksiyonu elde edilir.

$$G(x, y, \sigma) = \left[ \frac{1}{2\pi\sigma^2} \right] * e^{-(x^2+y^2)/2\sigma^2} \quad (1)$$

$$L(x, y, k\sigma) = G(x, y, k\sigma) * I(x, y) \quad (2)$$

I: orijinal resim, L: Ölçek uzay fonksiyonu, G: değişken orantıya sahip Gauss fonksiyonu, \* : Konvolüsyon operatörü,  $\sigma$  : Gauss ölçeğinde kullanılan standart sapma değeri.

Kilit noktalarının belirlenmesi = Kenar tespit yöntemleri kullanılarak önem arz eden kilit noktalar Gauss filtresinden geçirilerek iki resim arasındaki fark elde edilir. Kontrast değerleri baz alınır. Bu işlemde düşük kontrastlı noktalar elenir.

### b. Yönelim tespiti

Uç noktalarının her bir öznelik noktası için yönelim açısı ve büyüklüğü belirlenir. Her anahtar noktanın tüm komşu piksellerinde bu işlem yapılır. Bu işlem sonucunda bir veya birkaç öznelik noktası için yönelim vektörü atanır. Böylelikle seçilen öznelik noktası değişimlere karşı etkili hale getirilmiş olur. Bu işlem ile nesnedeki açısal değişimlerde nesneyi kaybetmememizi sağlayacaktır.

### c. Düşüm noktalarının niteliklendirilmesi

Üç boyutlu eksende görüntü içerisindeki nesnenin aydınlanma, dönme kaybı engellenir.

SIFT piksellerin gradyan boyunu ve yönünü hesaplar. Işıklandırma farklılıklarına karşı dayanıklılık için gradyan boyları maksimum gradyan değerinin 0.1 katı kullanılarak eşiklendirilir [14]. SIFT yönteminin üstün tarafları; görüntünün ölçeğinden, resmin boyutundan, kameranın açısından, ortamın ışık koşullarından etkilenmeden öznelikleri çıkarmasıdır [15].

### 3.2.2. Hızlandırılmış gürbüz öznelikler (Speeded-Up robust features)

Hessian matrisinin hesaplanmasına dayalı hızlandırılmış gürbüz öznelikler algoritmasıdır. Hessian'ın hesaplanmasında integral görüntüler kullanıldığı için hesaplama süresi düşer. Bu durum SURF algoritmasının SIFT algoritmasına göre daha hızlı çalışmasını sağlar. SURF, görüntü analizi için ölçek alanında Gauss tipi

süzgeçlerle ilgi noktalarını belirler [16]. SURF yaklaşımı anahtar nokta tespiti ve tanımlamasını içerir. Anahtar noktalar görüntü üzerindeki bir nokta için Hessian matrisi yaklaşımına dayanır [17]. SURF SIFT'ten farklı olarak Hessian matrisinin uç noktalarını kullanır. SURF döndürme ve ölçekleme durumlarında herhangi bir değişim göstermez.

$$H(x, y, \sigma) = [L_{xx}(x,y,\sigma) \ L_{xy}(x,y,\sigma) \ L_{xy}(x,y,\sigma) \ L_{yy}(x,y,\sigma)] \quad (3)$$

Bu formülde H Hessian matrisidir. Lxx standart sapmadır.  $\sigma$  Gauss süzgecinin x bağımsız değişkenine göre ikinci mertebeden kısmi türeviyle girdi görüntüsünün katlanması göstermektedir. Lxy ve Lyy ise Lxx ile aynı şekilde hesaplanır [18].

SURF algoritması, temel olarak 2 adımdan oluşmaktadır [16]:

- Anahtar noktaların yerinin saptanması: Anahtar noktalar, kutu filtrelerden elde edilen ölçeklerden yararlanarak bulunmaktadır. Farklı ölçek değerlerinde farklı sayıda anahtar nokta elde edilir. Ölçek değeri arttıkça bulunan anahtar nokta sayısı düşmektedir.
- Anahtar nokta tanımlayıcılarının oluşturulması: Anahtar noktalar elde edildikten sonra anahtar noktalar etrafında çember şeklinde bir alan seçilir ve bu alana Haar dalgacık filtreleri uygulanarak her bir anahtar nokta için bir tanımlayıcı elde edilerek öznelikler çıkarılmış olur [19].


### 3.2.3. Yerel ikili örüntü (Local binary pattern)

LBP operatörü, gri seviyeden bağımsız bir doku ölçümü yöntemidir. LBP operatörü görüntünün her pikseli için birler ve sıfırlardan oluşan bir etiket oluşturmaktadır. Bu etiketler merkez pikselin NxN komşuluğundaki piksellerin karşılaştırılmasıyla oluşturulmaktadır. Genel olarak LBP P,R üç farklı dairesel komşulukla tanımlanabilir. P komşu sayını, R ise örnekleme yarıçapını temsil etmektedir [20]. LBP formülü olarak

$$LBP_{P,R}(X_c) = \sum_{p=0}^{P-1} u(X_p - X_c)2^p$$

$$u(y) = \{1, y \geq 0 \quad 0, y < 0\} \quad (4)$$

Burada Xc=üretilen merkez pikseli, Xp=merkez pikselin komşularını, R komşuların merkez piksele olan uzaklığını, P ise işleme sokulan komşu sayısını ifade etmektedir. Şekil 4'te asçii koduna dönüştürülmüş bir görüntünün LBP yöntemi ile ikili koda dönüştürülmesine ilişkin bir örnek verilmiştir.



Şekil 4. LBP özellik çıkarım örneği (Example of LBP feature extraction)

Yeni oluşan LBP görüntüsündeki her değerın frekansını bir öznelık olarak kullanılır.

### 3.2.4. Gri düzey eş oluşum matrisi (Grey level co-occurrence matrix)

Gri Düzey Eş Oluşum Matrisi (Gray Level Co-Occurrence Matrix=GLCM) metodu Haralick ve arkadaşları [12]

tarafından farklı dokuların sınıflandırılması için önerilmiştir. GLCM geri seviye bağımlılık matrisi olarak da bilinir. GLCM yöntemi piksel tabanlı bir görüntü işleme yöntemidir. Gri seviyeli bir görüntüden öznelık elde etmek için pikseller arasındaki ilişkiyi kullanan bir yaklaşımdır. GLCM matrisini oluşturmak için; pikseller arası uzaklık (D), piksellerin açısı (0°, 45°, 90° ve 135°=θ) ve dönüşümün yapılacağı gri ton seviye sayısı (maksimum 256) parametreleri temel alınarak yapılmaktadır [21-23]

GLCM matrisi gri tonundaki görüntünün Şekil 5'te belirtilen işlem sırasına göre GLCM matrisi oluşturmaktadır.



Şekil 5. GLCM metodu işlem sırası (GLCM method processing order)

Tablo 1. GLCM yönteminde kullanılan özellikler ve formülleri (Formulas and features of GLCM method)

No	Özellik	Formül
1	Kontrast	$f_1 = \sum_{m=0}^{N_g-1} m^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,\theta^o}(i,j) \right\}$ $ i-j =m$
2	Korelasyon	$f_2 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (ij) p_{d,\theta^o}(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
3	Homojenlik	$f_3 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{p_{d,\theta^o}(i,j)}{1+(i-j)^2}$
4	ASM	$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,\theta^o}^2(i-j)$
5	Enerji	$f_5 = \sqrt{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,\theta^o}^2(i-j)}$
6	Dissimilarity	$f_6 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,\theta^o}^2(i,j)  i-j $

Heralick [22] GLCM matrisinden elde edilebilecek 14 adet doku özellik önermiştir. Bu çalışmada kullanılan enerji, korelasyon, kontrast, asm, benzeşmezlik ve homojenlik özellikleri Tablo 1’de gösterilmiştir.

### 3.2.5. Gradyan yönelimlerinin histogramı (Histogram of oriented gradient)

Gradyan Yönelimlerinin Histogramı (HOG-Histogram of Oriented Gradients) Dalal ve ark. [24] tarafından görüntüdeki piksellerin gradyanlarının büyüklüğünü ve yönünü tanımlamaktır. Gradyan, yön ve büyüklük bilgilerini içeren iki boyutlu bir vektördür. Görüntü en küçük pencerele bölünür ve her penceredeki gradyanların yönleri ve büyüklükleri sobel filtresi ile hesaplanır.

HOG öznelik çıkarımı:

1) Görüntünün gradyanlarının hesaplanması= Görüntünün yatay ve dikey Sobel filtreleri uygulanarak kenarları belirlenir (Eşitlik 5).

2) Histogram üretimi (Eşitlik 6).

3) Oluşan histogramların blok normalizasyonu

$$I_x=I*D_x \quad I_y=I*D_y \quad (5)$$

$$|G| = \sqrt{I_x^2 + I_y^2} \quad \theta = \arctan \frac{I_x}{I_y} \quad (6)$$

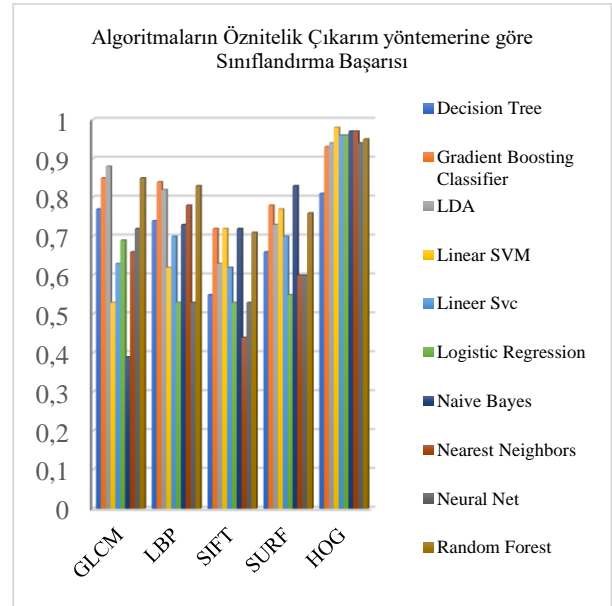
## 4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Bu çalışmada kullanılan görüntüler Demiryolu Araştırma Merkezi (DATEM)’den alınmıştır. Veri seti yüksek hızlı tren hattı üzerinde bulunan ölçüm treni üzerindeki V-CUBE sistemi tarafından elde edilen görüntülerden oluşmaktadır. V-CUBE sistemi trenlerin ön tarafına kolay bir şekilde monte edilebilen 50’den fazla farklı tipte arıza teşhisinde kullanılan bir sistemdir. Yenilikçi mimarisi sayesinde V-CUBE piyasadaki en iyi tespit oranını sunabiliyor. Bu sistemde 0 ile 200 km/s arasında hızlarda alınan görüntüler üzerinde analiz gerçekleştirilebilmektedir. Görüntüler, aracın hızına uyumlu bir ışık sistemi ve lineer tarayıcı kamera tarafından elde edilmiştir. Elde edilen görüntüler belirlenen problemlere göre 7 farklı sınıfa ayrılmıştır. Bu çalışmada kullanılan görüntü sayıları Tablo 2’de verilmiştir.

Tablo 2. Veri seti sınıfları ve görüntü sayıları (Data set classes and image numbers)

Problem Tipi	Görüntü Sayısı	Oran
Sol_Vida	33	2,98%
Sag_Vida	33	2,98%
Sol_Aparat	130	11,73%
Sag_Aparat	75	6,77%
Kirik_Ray	576	51,99%
Sol_Baglanti	130	11,73%
Sag_Baglanti	131	11,82%
TOPLAM	1108	% 100

Bu çalışma kapsamında görüntülerden beş farklı öznelik çıkarım yöntemi kullanılmıştır. Bu yöntemler ile elde edilen özneliklerden görüntüleri sınıflandırmak için 10 farklı makine öğrenmesi sınıflandırma algoritması kullanılmıştır. Sınıflandırma işlemleri 10 katlı çapraz geçerlilik testine göre gerçekleştirilmiştir. Bu algoritmaların farklı öznelik çıkarım yöntemlerine göre sınıflandırma başarıları Tablo 3’te ve bu sınıflandırma algoritmalarının başarıları grafik olarak Şekil 6’da gösterilmiştir.



Şekil 6. Sınıflandırma algoritmalarının başarıları (Success of classification algorithms)

Tablo 3. Öznitelik çıkarım yöntemlerine göre sınıflandırma algoritmalarının başarısı (Success of classification algorithms according to feature extraction methods)

	öznitelik	Performans Ölçütleri	Decision Tree	Gradient Boosting Classifier	LDA	Linear SVM	Lineer Svc	Logistic Regression	Naive Bayes	Nearest Neighbors	Neural Net	Random Forest
GLCM	6	Precision	0,59	0,69	0,74	0,1	0,2	0,35	0,31	0,42	0,41	0,71
		F1	0,58	0,76	0,81	0,08	0,31	0,37	0,36	0,42	0,42	0,78
		Accuracy	0,77	0,85	<b>0,88</b>	0,53	0,63	0,69	0,39	0,66	0,72	0,85
LBP	59	Precision	0,48	0,6	0,53	0,25	0,34	0,1	0,47	0,52	0,1	0,65
		F1	0,49	0,63	0,52	0,24	0,34	0,08	0,54	0,54	0,08	0,8
		Accuracy	0,74	0,84	<b>0,82</b>	0,62	0,7	0,53	0,73	0,78	0,53	0,83
SIFT	128	Precision	0,28	0,36	0,44	0,35	0,29	0,1	0,48	0,21	0,1	0,35
		F1	0,28	0,36	0,44	0,33	0,33	0,08	0,48	0,23	0,08	0,44
		Accuracy	0,55	<b>0,72</b>	0,63	<b>0,72</b>	0,62	0,53	0,72	0,44	0,53	0,71
SURF	128	Precision	0,38	0,4757	0,51	0,39	0,36	0,1	0,64	0,42	0,17	0,41
		F1	0,39	0,48	0,52	0,37	0,35	0,08	0,64	0,48	0,14	0,41
		Accuracy	0,66	0,78	0,73	0,77	0,7	0,55	<b>0,83</b>	0,6	0,6	0,76
HOG	3780	Precision	0,65	0,79	0,87	0,93	0,92	0,93	0,92	0,94	0,86	0,83
		F1	0,67	0,85	0,87	0,97	0,92	0,92	0,92	0,93	0,84	0,94
		Accuracy	0,81	0,93	0,94	<b>0,98</b>	0,96	0,96	0,97	0,97	0,94	0,95

Tablo 3'ten görüleceği gibi HOG yöntemine göre çıkarılan özniteliklerin Lineer SVM sınıflandırma algoritması ile %98 oranında doğru sınıflandırıldığı görülmektedir. Bu sonuç 5 farklı öznitelik çıkarım yöntemi ve 10 farklı sınıflandırma algoritması arasında en yüksek sınıflandırma başarısını gösteren sonuçtur. Ardından GLCM yöntemi ile elde edilen özniteliklere göre görüntüleri %88 oranında doğru sınıflandıran LDA algoritmasıdır. LBP yöntemine göre görüntülerden elde edilen özniteliklere göre en iyi sınıflandırma algoritması %82 oranında LDA algoritması olmuştur. SIFT yöntemine göre görüntülerden elde edilen özniteliklere göre en iyi sınıflandırma algoritması %72 ile GBC ve SVM algoritması olmuştur. SUFT yöntemine göre görüntülerden elde edilen özniteliklere göre en iyi sınıflandırma algoritması %83 oranında NB algoritması olmuştur. Genel olarak yüksek başarı oranları gözlenmiştir.

En başarılı yöntem yaklaşımı HOG+SVM olarak gözlemlenmiştir. İkinci sıradaki en başarılı yaklaşım ise GLCM+LDA olarak tespit edilmiştir. Bu iki yaklaşıma ait karışıklık matrisleri Tablo 4 ve Tablo 5'te gösterilmiştir. Tablodaki  $A=\{A1,A2...A7\}$  arıza kodlarını göstermektedir.

Tablo 4. HOG+SVM yaklaşımı için karışıklık matrisi (Confusion matrix for HOG+SVM approach)

	A1	A2	A3	A4	A5	A6	A7	Başarı
A1	33	0	0	0	0	0	0	%100
A2	0	28	0	5	0	0	0	%84,84
A3	0	0	130	0	0	0	0	%100
A4	0	0	0	75	0	0	0	%100
A5	0	0	0	0	576	0	0	%100
A6	0	0	0	0	0	130	0	%100
A7	0	7	0	0	0	15	109	%83,20

Tablo 4'e bakıldığında sadece A2 ve A7 sınıfları için (BOLT\_RIGHT ve SLEEPER\_RIGHT) yanlış sınıflandırmanın olduğu görülmektedir. Diğer arıza türleri için %100 başarı oranı gözlenmiştir. HOG+SVM yaklaşımının başarılı olmasının sebebi HOG yöntemi ile çok fazla özniteliğin çıkarılmasından kaynaklandığı düşünülmektedir.

Tablo 5'teki sonuçlar incelendiğinde en düşük başarımın A1 (SOLT\_LEFT) sınıfı için elde edilmiştir. En yüksek başarı oranları ise A2 sınıfı (BOLT\_RIGHT) için gözlenmiştir.



Tablo 5. GLCM+LDA yaklaşımı için karışıklık matrisi  
(Confusion matrix for GLCM+LDA approach)

	A1	A2	A3	A4	A5	A6	A7	Başarı
A1	17	0	0	0	0	16	0	%51,51
A2	0	33	0	0	0	0	0	%100
A3	0	0	106	24	0	0	0	%81,53
A4	0	7	7	54	0	0	7	%72,00
A5	0	0	0	10	566	0	0	%98,26
A6	0	0	0	12	0	95	23	%73,06
A7	0	8	0	0	0	0	123	%93,89

## 5. TARTIŞMA (CONCLUSION)

Demiryolu ulaşımı insan ve yük taşımacılığında yoğun olarak kullanılan bir ulaşım şeklidir. Demiryolu bileşenlerinde oluşacak herhangi bir hata maddi ve manevi birçok kayba neden olabilir. Bu kayıpların önüne geçmek için bu hataların erken tespit edilmesi çok önemlidir. Bu çalışmada tren ray görüntülerinden bağlantı noktasında vidası olmayan, sıkma aparatında problem olan, ray çatlakları, travers çatlakları bulunan ve traversler arası mesafesi fazla veya az olan görüntülerden oluşan 7 farklı sınıfa ait hatalar görüntü işleme teknikleri kullanılarak tespit edilmeye çalışılmıştır.

Görüntülerin başarılı sınıflandırılması için öznelik çıkarım yöntemleri çok önemlidir. Bu çalışmada GLCM, LBP, SURF, SIFT ve HOG gibi farklı öznelik çıkarım yöntemleri kullanılarak ray görüntülerinden öznelik vektörleri oluşturulmuştur.

Elde edilen öznelik vektörleri farklı sınıflandırma metotları ile test edilmiştir. Sınıflandırma için 10 farklı algoritma kullanılmıştır. Bu çalışmada kullanılan görüntüler HOG yöntemi ile %98 oranında Lineer SVM sınıflandırma algoritması ile doğru bir şekilde sınıflandırılmıştır. Daha sonra GLCM yöntemi ile görüntüler SVM algoritması ile %88 oranında, SURF yöntemi ile %83 oranında NB sınıflandırma algoritması ile görüntüler doğru sınıflandırılmıştır. En kötü sonuçları SIFT yöntemi ile elde edilmiştir. SIFT yöntemine göre %72 doğru sınıflandırma başarısı elde edilmiştir.

## TEŞEKKÜR (ACKNOWLEDGMENT)

Bu çalışmada TCDD, Demiryolu Araştırma Teknoloji Merkezi Müdürlüğü (DATEM)'ne görüntülerin elde edilmesinde sağladıkları yardımlardan dolayı teşekkür ederiz.

## KAYNAKLAR (REFERENCES)

[1] A. Lasisi, N. Attoh-Okine, "Principal components analysis and track quality index: a machine learning approach" *Transp. Res. Part C: Emerg. Technol.*, 91, 230-248, 2018.

[2] M. Boccione, A. Caprioli, A. Cigada, A. Collina, "A measurement system for quick rail inspection and effective track maintenance strategy", *Mechanical Systems and Signal Processing*, 21(3), 1242-1254, 2007.

[3] L. Zhuang, L. Wang, Z. Zhang, K.L. Tsui, "Automated vision inspection of rail surface cracks: a double-layer data-driven framework", *Transp. Res. Part C Emerg. Technol.*, 92, 258-277, 2018.

[4] M. Chenariyan Nakhaee, D. Hiemstra, M. Stoelinga, M. van Noort, "The Recent Applications of Machine Learning in Rail Track Maintenance: A Survey", *Lecture Notes in Computer Science*, 91-105, 2019.

[5] I. Durazo-Cardenas, et al, "An autonomous system for maintenance scheduling data-rich complex infrastructure: fusing the railways' condition, planning and cost", *Transp.Res.Part C Emerg.Technol.*, 89, 234-253 2018.

[6] X. Gibert, V.M. Patel, R. Chellappa, Deep multitask learning for railway track inspection, *IEEE Trans, Intell, Transp, Syst*, 18, 153-164, 2017.

[7] S. Öztürk, N. Öztürk, "Yapay Arı Koloni Algoritması Kullanılarak Görüntü İyileştirme Yönteminin Geliştirilmesi" *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 4(4), 173-183, 2016.

[8] R. Biswas, R. A. Khan, S. Islam, J. Uddin, "A Novel Approach to Detect and Classify the Defective of Missing Rail Anchors in Real-time", *International Journal of Emerging Technology and Advanced Engineering*, 6(12), 2016.

[9] J. Liu, B. Li, Y. Xiong, B. He, L. Li, "Integrating the Symmetry Image and Improved Sparse Representation for Railway Fastener Classification and Defect Recognition", *Hindawi Publishing Corporation, Mathematical Problems in Engineering*, 2015.

[10] M. Karakose, O. Yaman, K. Murat, E. Akin, "A new approach for condition monitoring and detection of rail components and rail track in railway", *International Journal of Computational Intelligence Systems*, 11(1), 830-845, 2018.

[11] Y. Xia, F. Xie, Z. Jiang, "Broken railway fastener detection based on adaboost algorithm", **International Conference on Optoelectronics and Image Processing (ICOIP '10)**, 313-316, Haiko, China, November 2010.

[12] H. Serce, Y. Bastanlar, A. Temizel, Y. Yardimci, "On Detection of Edges and Interest Points for Omnidirectional Images in Spheria Domain", **SIU 2008**, Didim, Aydın, 20-22 April, 2008.

[13] F. Amasyali, A. Münük, "Kamera görüntülerinden gidilen yolun kestirimi", *Engineering Sciences* 6(1), 296-304, 2011.

[14] D. Lowe, "Object recognition from local scale-invariant features", **Proceedings of the International Conference on Computer Vision**, 2, 1150-1157, 1999.

[15] B. Akan, M. Çetin, A. Erçil, "Stereo based 3D head pose tracking using the scale invariant feature transform", **2008 IEEE 16th Signal Processing, Communication and Applications Conference**, IEEE, 1-4, 2008.

[16] H. Bay, A. Ess, T. Tuytelaars, L. Van Gool, "Speeded-up robust features (SURF)", *Computer vision and image understanding*, 110(3), 346-359, 2008.

[17] Ü. Atila, K. Akyol, F. Sabaz, "Retinal Görüntülerde Eksuda Lezyonlarının Tespiti Üzerine Bir Çalışma", *Bilişim Teknolojileri Dergisi*, 13(1), 27-36, 2020.



- [18] Y. Aydın, "Dizdarođlu, Bekir. Image inpainting with local feature extraction", **2018 26th Signal Processing and Communications Applications Conference (SIU)**, IEEE, 1-4, 2018.
- [19] K. Mikolajczyk, C. Schmid, "A performance evaluation of local descriptors", *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, 27(10), 1615-1630, 2005.
- [20] B. Yang, S. Chen, "A comparative study on local binary pattern (LBP) based face recognition: LBP histogram versus LBP image", *Neurocomputing*, 365-379, 2013.
- [21] R. M. Haralick, K. Shanmugan "Dinstein, Its' Hak, Textural features for image classification", *IEEE Transactions on systems, man, and cybernetics*, 6, 610-621, 1973.
- [22] S.N. Ondimu, H. Murase, Effect of probability-distance based Markovian texture extraction on discrimination in biological imaging, *Computers and Electronics in Agriculture*, 63(1), 2-12, 2008.
- [23] C.S. Hemalatha, V. Vaidehi, R. Lakshmi, "Minimal infrequent pattern based approach for mining outliers in data streams", *Expert Systems with Applications*, 42(4), 1998-2012, 2015.
- [24] N. Dalal, B. Triggs, "Histograms of oriented gradients for human detection," **IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, IEEE, 1, 886-893, 2005.