



Demiryolu Bağlantı Elemanlarında Bulunan Kusurların YOLOv4 ve Bulanık Mantık Kullanarak Tespiti

Emre GÜÇLÜ^{*}, İlhan AYDIN, Kadir ŞAHBAZ, Erhan AKIN, Mehmet KARAKÖSE

Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Bölümü, Elazığ, Türkiye

*emreguclu1367@gmail.com

(Alınış/Received: 20.05.2021, Kabul/Accepted: 15.06.2021, Yayınlama/Published: 31.07.2021)

Öz: Demiryollarında bulunan bağlantı elemanları, raylı sistemlerin en önemli bileşenidir. Bağlantı elemanları, diğer bileşenleri birbirine bağlar ve trenin raylar üzerinde güvenli bir şekilde hareket etmesini sağlar. Bu nedenle, hasarlı bağlantı elemanlarının tespiti, demiryolu taşımacılığının güvenliğini sağlamak için önemlidir. Bağlantı elemanlarının kontrolü genellikle eğitimli çalışanlar tarafından görsel olarak yapılır. Güvenlik standartlarını sağlayabilmek için binlerce kilometrelik hat, insanlar tarafından denetlenmelidir. Ancak bu yöntem, hız açısından oldukça sınırlıdır ve ihmallere neden olabilir. Bu nedenle, otomatik denetim sistemlerinin geliştirilmesine ihtiyaç vardır. Bu çalışmada, kırık bağlantı elemanlarını tespit etmek için, YOLOv4 ve bulanık mantık yapısına dayanan yeni bir yöntem önerilmiştir. Bağlantı elemanı görüntüsü 6 ayrı parçaya bölünerek etiketlenmiştir. Bağlantı elemanı görüntülerine YOLOv4 algoritmasının uygulanması ile 6 parçanın güven değerleri oluşturulmuştur. Oluşan 6 farklı güven değeri bulanık mantık yapısı için giriş değeri olarak verilmiştir ve bağlantı elemanın sağlık durumu hakkında yüzde cinsinden sonuç değeri üretilmiştir. Deney sonuçları, doğru tespit oranının %99 üzerinde olduğunu göstermiştir.

Anahtar kelimeler: Demiryolları, Bağlantı elemanı, YOLOv4, Bulanık mantık

Detection of Defects in Railway Fasteners Using YOLOv4 and Fuzzy Logic

Abstract: Fasteners in railways are the most important component of rail systems. Fasteners clamp other components together and allow the train to move safely on rails. Therefore, the detection of damaged fasteners is important to ensure the safety of rail transport. Detection of fasteners is usually done visually by trained employees. Thousands of kilometers of line must be inspected by people to ensure safety standards. However, this method is very limited in terms of speed and can cause negligence. Therefore, there is a need for the development of automatic control systems. In this study, a new method based on YOLOv4 and fuzzy logic is proposed to detect broken fasteners. The fastener image is divided into 6 separate parts and labeled. Confidence values of 6 parts were created by applying the YOLOv4 algorithm to the fastener images. The resulting 6 different confidence values are given as the input value for the fuzzy logic structure and a result value in percent about the health status of the fastener is produced. Experiment results showed that the correct detection rate was over 99%.

Keywords: Railways, Fastener, YOLOv4, Fuzzy logic

1. Giriş

Demiryolu ulaşımı, yolcu ve yük taşınmasında geçmişten günümüze kadar vazgeçilmez bir ulaşım şekli olmuştur. Demiryolu ulaşımı, özellikle son yıllarda yüksek hızlı trenlerin de gelişmesiyle büyük oranda tercih edilmektedir [1]. Demiryolu taşımacılığının hızlı gelişimi ile birlikte denetim ve bakımın önemi de artmıştır. Demiryolu güvenliğini artırmak için hatların belirli aralıklarla denetlenmesi gereklidir. Demiryolu bakımında, hat profil ölçümü [2], ray arızası tespiti [3], bağlantı elemanlarında bulunan kusurların tespiti [4] gibi görevler yer almaktadır. Bu çalışmada, demiryolu bakımının önemli bir parçası olan bağlantı elemanlarındaki kusurların tespitine odaklanılmıştır.

Atıf için/Cite as: E. Güçlü, İ. Aydin, K. Şahbaz, E. Akin, M. Karaköse, "Demiryolu bağlantı elemanlarında bulunan kusurların YOLOv4 ve bulanık mantık kullanarak tespiti," *Demiryolu Mühendisliği*, no. 14, pp. 249-262, July. 2021. doi: 10.47072/demiryolu.939830

Bağlantı elemanlarının kontrolü demiryolu incelemesinin önemli bir parçasıdır. Demiryollarında bulunan elemanlarda oluşabilecek kusurların erken tespiti güvenliği etkileyebilecek durumların engellenmesinde önemlidir. Trenlerin ray ile teması neticesinde oluşan titreşim ile birlikte, ray bağlantı elemanlarında kırılma ve eğilme gibi kusurların meydana gelmesi muhtemeldir. Bu elemanlar, demiryolu balast yatağı üzerinde bulunana elemanların birbirine bağlanmasında kritik role sahiptir. Bu nedenle ray bağlantı elemanları, raylı sistemler için çok önemli bir bileşendir. Bağlantı elemanlarında kusur bulunması, travers gibi diğer elemanları da etkileyecektir. Bu kusurların tespit edilememesi durumunda demiryolunda uzun vadede ciddi güvenlik sorunları meydana getirecektir.

Bağlantı elemanları geleneksel olarak demiryolu hattı boyunca yürüyen ve bağlantı elemanlarını görsel olarak inceleyen uzman çalışanlar tarafından yapılmaktadır. Ancak bu yöntem yavaş ve verimsizdir. Ayrıca sonuçlar, inceleme yapan çalışana göre öznel olarak değişir. Bu durum da ihmallerin yapılmasına sebep olabilir. Bu nedenle, denetlemenin daha hızlı ve güvenli yapılabilmesinin sağlanması ve yeni yöntemlerin keşfi için çeşitli çalışmalar yapılmaktadır. Hatayı tespit etmek için gelişmiş teknolojilerden yararlanan temassız, sürekli, düşük maliyet, yüksek hız avantajlarına sahip görüntü işleme teknolojisi, derin öğrenme, makine öğrenmesi gibi yöntemler yapılan çalışmalarla kullanılmaktadır. [5]'te, bağlantı elemanlarının yerinde olup olmadığı çok katmanlı algılayıcı sinir sınıflandırıcısı ile kontrol edilmiştir. [6]'da, bir lazer taramalı CCD kamerası görüntüünü analiz ederek gerçek zamanlı görüntü işleme tabanlı bir teknik uygulanmıştır. [7]'de bağlantı elemanlarının yön alanına dayalı olarak ağırlık katsayısı matrisi üretilmiştir. Eksik bağlantı elemanı tespiti yapılmıştır. [8]'de bağlantı elemanlarının tespiti için dalgacık dönüşümü yöntemi uygulandıktan sonra şablon eşleştirme yöntemi kullanılmıştır. [9]'da, Grafik İşleme Birimi (GPU) paralel işleme kullanılarak yüksek hızda, bağlantı elemanlarının yerinde olup olmadığını tespit edebilen tam otomatik ve gerçek zamanlı yeni bir inceleme sistemi sunulmuştur. [10]'da, demiryolu hatlarının sınıflandırılması için Otomatik Makine Öğrenimi (AutoML) yöntemlerinin kullanılabilirliği araştırılmıştır. [11]'de, bağlantı elemanlarını modellemek için olasılık tabanlı Yapısal Konu Modeli önerilmiştir. Aşınmış bağlantı elemanlarının olasılıkları, sağlam olanlar ile karşılaştırılarak bağlantı elemanın durumu hakkında yorum yapılmıştır. [12]'de bağlantı elemanlarının yerleri şablon eşleştirme yöntemi ile bulunup. Bağlantı elemanın yerinde olup olmadığı K-en Yakın Komşu algoritması kullanılmıştır.

Yapılan çalışmalar incelendiğinde bağlantı elemanın kusur durumunu incelemek için çeşitli yöntemler kullanıldığı görülebilir. Son yıllarda derin öğrenmenin gelişmesiyle bağlantı elemanı tespitinde kullanılabilecek çeşitli algoritmalar ortaya çıkmıştır. Bunlardan R-CNN [13] ve Fast R-CNN [14] gibi algılama tabanlı algoritmalar ile YOLOv3 [15] ve YOLOv4 [16] gibi regresyon tabanlı yöntemler sıkılıkla kullanılmaktadır. [17]'de, GPR profilindeki kusurları tanımak için Faster R-CNN çerçevesi kullanılarak derin öğrenmeye dayalı yöntem önerilmiştir. [18]'de, bağlantı elemanlarının tespiti için özelleştirilmiş Hibrit YoloV4 modeli kullanılmıştır. [19]'da, bağlantı elemanı kusur tespiti için derin öğrenme algoritmaları kullanılarak çalışmalar yapılp sonuçlar karşılaştırılmıştır.

Bu çalışmada, demiryolu bağlantı elemanın tanınması ve kusurların tespiti için YOLOv4 ve bulanık mantık yapısına dayalı yeni bir yöntem önerilmiştir. Bağlantı elemanında detaylı inceleme yapabilmek için bağlantı elemanı görüntüsü bütün olarak değil, parçalara ayrılarak her bir parça ayrı olarak incelemiştir. Görüntüyü parçalara ayırarak inceleme yöntemi, geleneksel yöntemlere kıyasla tanıma doğruluğunu artırır. Bağlantı elemanı parçaları YOLOv4 ağının tarafından tanıdıktan sonra güven değerleri bulanık mantık yapısında giriş olarak kullanılarak bağlantı elemanın durumu hakkında yüzde cinsinden çıkış değeri elde edilmiştir. Bulanık mantık sistem tasarımı Scikit-Fuzzy kullanılarak Python üzerinde gerçekleştirilmiştir. Bu makalenin geri kalanı şu şekilde düzenlenmiştir: Bölüm 2, önerilen yöntemin uygulanması için

yapılan ön hazırlık işlemleri, YOLOv4 ağı ve tasarlanan bulanık mantık yapısını içermektedir. Bölüm 3, önerilen yöntemin bağlantı elemanlarında bulunan kusurların tespiti için uygulanması ve deneysel sonuçları içermektedir. Son olarak Bölüm 4'te, önerilen yöntemin sonuçları ve gelecekteki kullanımı sunulmuştur.

2. Metot

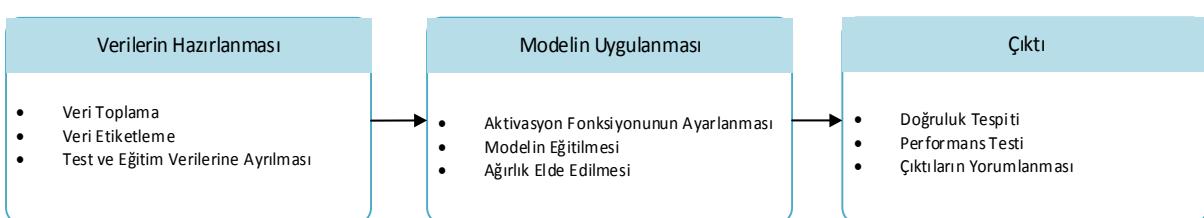
Önerilen yöntemde, bağlantı elemanlarının tespiti ve kusur durumunun belirlenebilmesi için derin öğrenme ve bulanık mantık yapısı kullanılarak yeni bir algoritma uygulanmıştır. Bağlantı elemanlarının tespiti için YOLOv4 algoritması kullanılmıştır. İlk olarak, bağlantı elemanı görüntüsü 6 bölgeye ayrılarak her bölge etiketlenmiştir. Bu işlemin amacı, bağlantı elemanın kusur durumunu ayrıntılı inceleyebilmektir, çünkü bağlantı elemanları titreşim ve sıcaklık değişiminin uzun vadeli etkileri ile zarar görebilir. Hasarlı bağlantı elemani; kısmen aşınıp etkinliğini yitirmiş olabilir, kısmen kırılmış veya tamamen kırılmış olabilir. Şekil 1'de bazı kusurlu bağlantı elemanı görüntüleri verilmiştir. Görüleceği üzere bağlantı elemanları farklı bölgelerden kırılmış veya eğilmiş olabilir. Bu nedenle bağlantı elemanın tek parça yerine 6 parçaya bölünerek incelenmesi daha uygun olacaktır. Tespit edilen 6 parçanın güven değeri, 6 girişli tek çıkışlı bulanık mantık yapısında kullanılarak bağlantı elemanın sağlık durumu hakkında çıkış değeri elde edilmiştir.



Şekil 1. Kusurlu bağlantı elemanı örnekleri

2.1 Bağlantı elemanlarının tespiti için YOLOv4 algoritmasının uygulanması

Model uygulanmadan önce verilerin hazırlanması gerekmektedir. Veri hazırlama işleminden sonra yapılan işlemlerin akış diyagramı Şekil 2'deki gibidir.



Şekil 2. Yapılan işlemlerin akış diyagramı

Eğitim işlemi için standart hale getirilmiş ve etiketlenmiş 2100 adet görüntü kullanılmıştır. YOLO algoritmasında eğitim işlemi için kullanılacak görüntülerin kısıtlaması yoktur. Veri setinde az görüntü bulunması aşırı öğrenmeye neden olabilir. Veri seti büyük olsa da her çeşitlilik yok ise yine aşırı öğrenme durumu ortaya çıkabilir. Bu çalışmada, kullanılan bağlantı elemanı görüntüleri ray üzerinden toplanan görüntülerden kırıplararak elde edilmiştir. Verilerdeki çeşitliliği sağlamak için farklı aydınlatma koşullarında görüntüler kullanılmıştır. Veri seti etiketleme işlemi için 6 bölge belirlenmiştir. Bölgelerin sınırları seçilirken kırılma veya eğilmenin olabileceği bölgeler dikkate alınmıştır. Bölgelerin sınırları Şekil 3.b'de gösterilmiştir. Görüntülerin 6 parçaya bölünmesinin amacı bağlantı noktalarını sınırlayarak YOLO ağının bağlantı plakasını bir bütün halinde değil

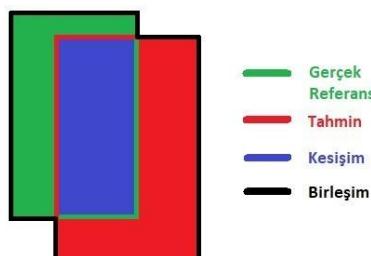
parçalar halinde öğrenmesini sağlamaktır. Bağlantı elemanı görüntülerinin parçalara ayrılması bölgесel hataların tespit oranını artırılmıştır. Ayrıca bağlantı plakasının bölgесel hatalarının tespiti için bulanık mantık kullanılmاسının önünü açmıştır.



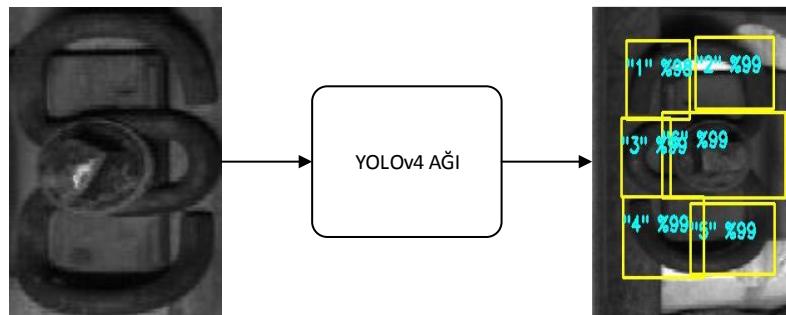
YOLOv4, darknet framework üzerinde geliştirilmiş bir nesne tespit algoritmasıdır. YOLOv4 ağı, hızlı çalışması nedeniyle birçok uygulamada kullanılır. Derin evrişimli sinir ağlarını kullanarak nesneleri tespit eder ve kutucuklar içerisinde gösterir. Veriler eğitildikten sonra, YOLOv4 ağına bir test görüntüsü verildiğinde çıkış olarak görüntü üzerinde bulunan nesnelerin hangi sınıf'a ait olduğunu gösterir (Şekil 5). Güven skoru, tahmin edilen nesnenin gerçek nesneye ne kadar benzediğini göstermektedir. Nesnenin güven skoru 0 ve 1 arasında oluşturulmaktadır. Güven skoru Denklem 1'deki gibi hesaplanmaktadır.

$$\text{Güven Skoru} = \text{Pr}(\text{Nesne}) * \text{IoU} \quad (1)$$

$$\text{IoU} = \frac{\text{Kesişim(Gerçek - Referans} \cap \text{Tahmin)}}{\text{Birleşim(Gerçek - Referans} \cup \text{Tahmin)}} \quad (2)$$



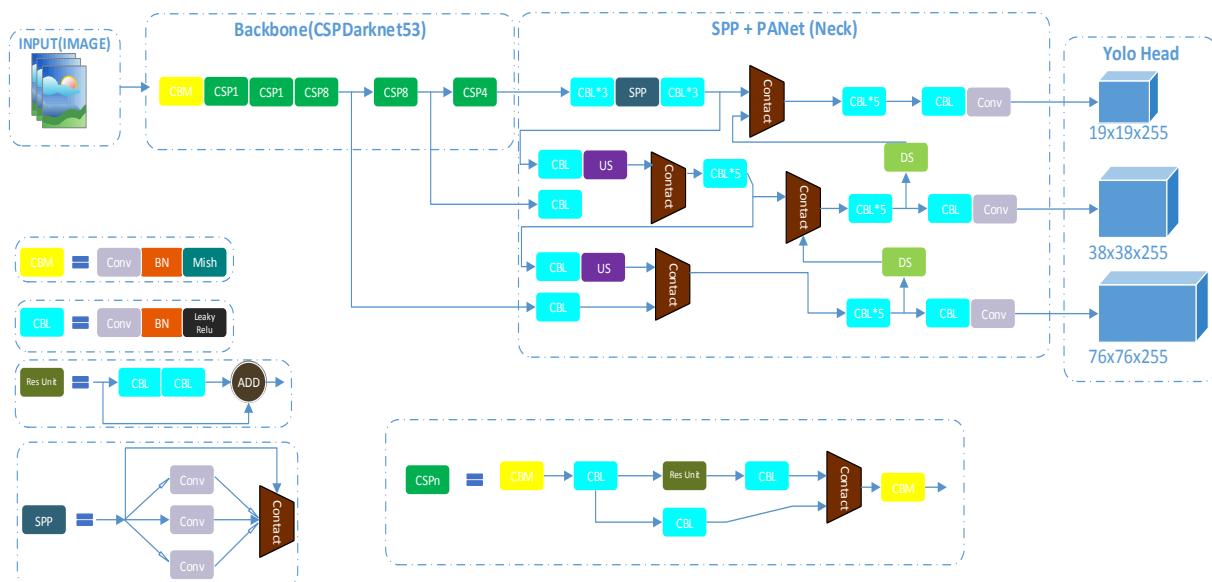
Şekil 4'te gösterildiği gibi gerçek referans ve tahmin kutucuklarının kesişimleri IoU (Intersection over Union) olarak ifade edilmiştir. IoU değeri Denklem 2'de gösterildiği gibi hesaplanır.



Şekil 5. YOLOv4 ağı giriş çıkış örneği

YOLOv4 ağı; omurga, boyun ve kafa olmak üzere üç temel bölümden oluşmaktadır. Omurga, farklı görüntü tanecikleri üzerinden özellik toplayan ve oluşturan evrişimsel sınır ağıdır. YOLOv4 içinde CSPDarknet53 [20] kullanılmıştır. Ayrıca Bag of freebies ve Bag of specials isimli iki bölüm daha bulunur. Bu bölümler veri setini zenginleştirmek için kullanılır. Boyun, nesneleri farklı ölçeklerde algılamak için kullanılır. Kafa bölümünü besleyen bilgileri zenginleştirmek için aşağıdan-yukarı, yukarıdan- aşağı akıştan gelen özellik haritaları kafa bölümünü beslemeden önce eleman bazında veya birleştirilerek birbirine eklenir. YOLOv4'te SAM [21], SPP [22], PANet [23] kullanılır. Kafa bölümü, Dense Prediction katmanıdır. YOLOv3 ile aynı yapı kullanılmıştır. Görevi ise nesnenin koordinatlarını, güven skorunu ve etiketini içeren bir vektör oluşturmaktır. YOLOv4 mimarisi Şekil 6'da gösterilmiştir.

YOLO, tek aşamalı nesne tespiti(One-Stage Detector) yapmaktadır. Sparse Prediction katmanı; Faster R-CNN, R-CNN gibi algoritmalarla kullanılmaktadır ve bu algoritmalar iki aşamalı olarak nesne tespitini yapar. Kullanılacak veri setini zenginleştirme ve optimizasyon işlemleri için Bag of freebies ve Bag of specials paketleri kullanılmıştır. Bag of freebies, veri zenginleştirme işlemi için kullanılır ve ağın başarısını artırır. Fakat ağın hızını etkilemez.



Şekil 6. YOLOv4 mimarisi

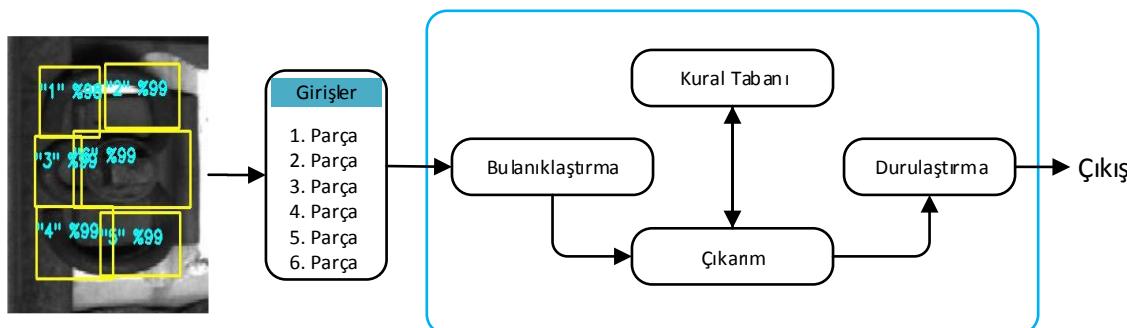
2.2 Kusur tespiti için tasarlanan bulanık mantık yapısı

Test görüntüsüne YOLOv4 algoritmasının uygulanması ile 6 farklı güven değeri oluşturulmuştur. Oluşan 6 farklı güven değeri dikkate alınarak bağlantı elemanın durumu hakkında yorum yapmak zordur. Demiryolunda binlerce bağlantı elemanı olduğu düşünülürse hepsinin

incelenmesi uzun zaman alacaktır. Bu nedenle, oluşan güven değerlerini kullanarak otomatik denetim sistemi oluşturmak şarttır. Bu tür karmaşık durumların olduğu durumlarda, insan beynine benzer tahminler yapmak için bulanık mantık kullanılabilir [24]. Bu nedenle, güven değerleri kullanılarak kusur tespiti yapmak için bulanık mantık kullanılacaktır.

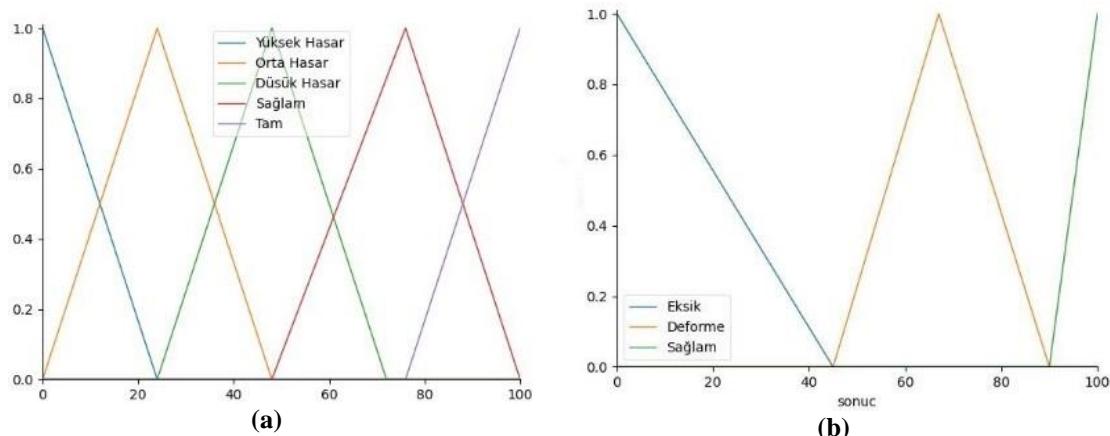
Bulanık mantık terimi, Lotfi Zadeh tarafından 1965 tarihli bulanık küme teorisi önerisiyle tanıtılmıştır [25]. Bulanık Mantık, insanın düşünme yapısına benzeyen bir akıl yürütme yöntemidir. Bulanık mantık yaklaşımında, dijital değerler “0” ve “1” arasındaki tüm ara olasılıkları içeren karar verme şeklini taklit eder. Bağlantı elemanlarının kusur tespiti için düşünülürse, çıktı durumu klasik kümede “hasarlı” ve “sağlam” şeklinde kesin sonuç üretilebilir. Ancak, bulanık kümede “eksik”, “orta hasarlı”, “az hasarlı”, “sağlam” gibi sonuçlar üretilebilir.

Bulanık mantık; bulanıklaştırma birimi, çıkışım birimi, kural tabanı ve durulaştırma birimi olmak üzere dört ayrı birimden oluşur. Bulanıklaştırma biriminde, giriş bilgileri dilsel niteleyicilere dönüştürülür. Giriş bilgilerinin ait olduğu üyelik dereceleri tespit edilir. Bu nedenle, bulanık mantık kullanılarak görüntüdeki bağlantı elemanın durumunun değerlendirilmesi için ilk olarak giriş görüntüsü giriş fonksiyonlarına göre işlenir ve her kümenin üyelik dereceleri belirlenir. Daha sonra bulanık çıkışım tasarılanır. Çıkış işlemi kurallara göre yapılır. Kurallar, “eğer-değilse” koşullarına göre tasarlanmıştır. Son olarak, durulaştırma işlemi uygulanır. Durulaştırma işlemi sonucunda, bulanık değerler insanlar tarafından anlaşılabılır hale getirilir. Kullanılan bulanık sistemin blok diyagramı Şekil 7'deki gibidir.



Şekil 7. Bulanık mantık yapısı

YOLOv4 algoritması sonucunda tespit edilen parçaların güven değerlerine göre kusur durumları hakkında çıkış üretilmesi amaçlanmıştır. Bu amaç doğrultusunda giriş ve çıkış değerlerinin isimleri, sayıları ve limitleri belirlenmiştir. Giriş için belirlenen 6 farklı giriş değeri için üyelik fonksiyonları Şekil 8.a' da gösterilmiştir. Şekil 8.b ise çıkış için üyelik fonksiyonlarını göstermektedir. Şekil 8.b'de görüldüğü gibi %0 ile %45 aralığında sonuç alınırsa “eksik”, %45 ile %90 aralığında sonuç alınırsa “deforme”, %90 üzerinde sonuç alınırsa “sağlam” olarak nitelendirilecektir. Oluşturulan kurallar ise Tablo 1'de verilmiştir.



Şekil 8. Giriş ve çıkış için oluşturulan üyelik fonksiyonları (a) Girişler için üyelik fonksiyonları (b) Çıkış için üyelik fonksiyonları

Tablo 1. Kurallar

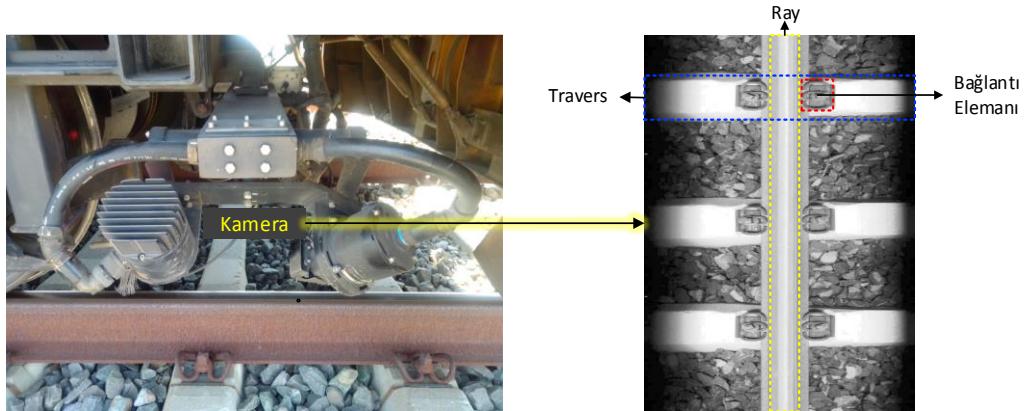
Girişler							Çıkış
1. Parça	2. Parça	3. Parça	4. Parça	5. Parça	6. Parça	Sonuç	
YH	YH	YH	YH	YH	YH	E	
OH	OH	OH	OH	OH	OH	D	
DH	DH	DH	DH	DH	DH	D	
S	S	S	S	S	S	S	
T	T	T	T	T	T	S	

Tabloda YH; yüksek hasar, OH; orta hasar, DH; düşük hasar, S; sağlam, T; tam, E; eksik ve D; deform olarak kodlanmıştır.

3. Deneysel Sonuçlar

Bağlantı elemanı kusurlarını incelemek için verilerin demiryolundan düzgün bir şekilde toplanması gerekmektedir. Bu çalışmada veriler, Şekil 9'da gösterilen Türkiye Cumhuriyeti Devlet Demiryolları Araştırma Merkezi (DATEM) tarafından bir ölçüm treni üzerinden elde edilmiştir. Veri toplama işlemi için yüksek çözünürlüklü kameraların kullanılması gerekmektedir. Ancak, yüksek çözünürlüklü kamera kullanılmasına rağmen toplanan görüntüler aydınlatma açısından aynı nitelikte değildir. Şekil 9'da görüldüğü gibi kameralar trenin yan taraflarına kurulmuştur. Bu nedenle, görüntü toplama sırasında güneş ışığının geliş açısı sürekli değişmektedir. Bu durum da, elde edilen görüntülerin parlaklığını önemli ölçüde etkilemektedir. Bu dezavantajın üstesinden gelebilmek için görüntüler ön işleme aşamasından geçirilerek daha net görüntüler elde edilmelidir. Görüntü önişleme, kontrast artırma işlemini içermektedir.

Demiryolundan elde edilen görüntülere göre, bağlantı elemanlarının durumlarının çeşitli olduğu belirlenmiştir. Bu nedenle, bağlantı elemanın durumu tür açısından, sağlam, deform ve eksik olmak üzere üç farklı türde ayrılmıştır. Bağlantı elemanın sahip olabileceği üç farklı durum, önerilen algoritma üzerinde test edilmiştir. Şekil 10'da sağlam, Şekil 11'de deform ve Şekil 12'de eksik bağlantı elemanları için görüntülerinin analiz edildiği, önerilen algoritmanın sonuçları gösterilmektedir. Çıkış yüzdesi %0 ile %45 arasında ise “eksik”, %45 ile %90 arasında ise “deform”, %90 üzeri ise “sağlam” olarak nitelendirilecektir.

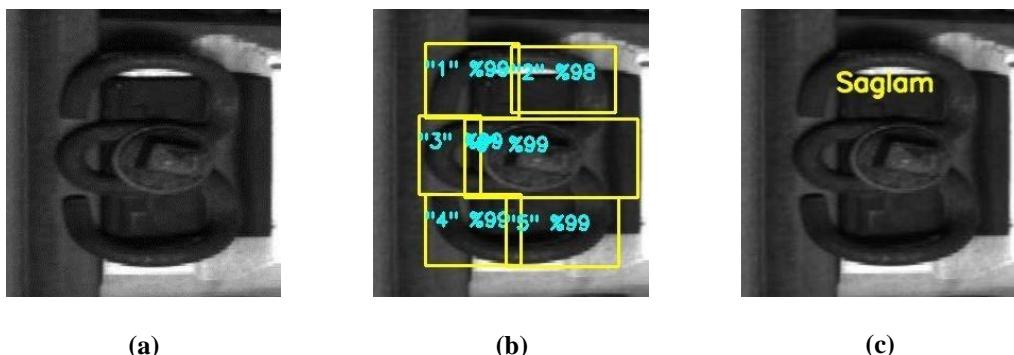


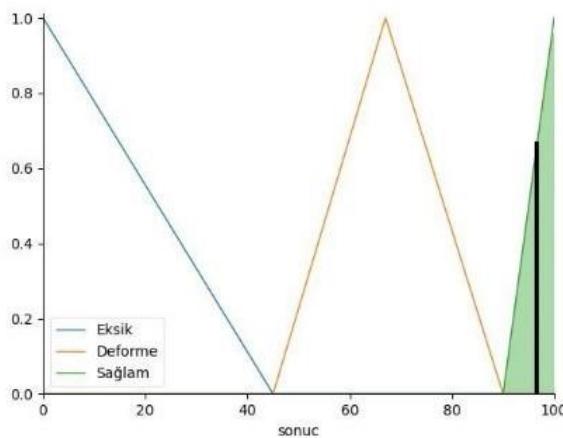
Şekil 9. Verilerin toplanması için kurulan sistem

Şekil 10.a'da görüldüğü gibi bağlantı elemanı sağlamadır. Bu nedenle Şekil 10.b'de 6 ayrı parça yüksek yüzdeli güven değerleri oluşturmuştur. Sonuç olarak, bağlantı elemanı sağlam olarak nitelendirilmiştir (Şekil 10.c). Şekil 10.d'de gösterilen sonuç grafiğine göre bağlantı elemanın sağlamlığı %90 üzeri olarak bulunmuştur.

Şekil 11.a'da görüldüğü gibi bağlantı elemanın alt kısmı eğilmiştir. Bu nedenle Şekil 11.b'de üstteki dört bölüm yüksek yüzdeli güven değerleri oluştururken alttaki iki bölüm kusurlu olması nedeniyle düşük güven değerleri oluşturmaktadır. Bu da sonuç yüzdesini azaltmaktadır. Bu nedenle, Şekil 11.c'de görüldüğü gibi deform olarak nitelendirilmiştir. Şekil 11.d'de gösterilen sonuç grafiğine göre bağlantı elemanın sağlamlık yüzdesi %45 ile %90 aralığında bulunmaktadır.

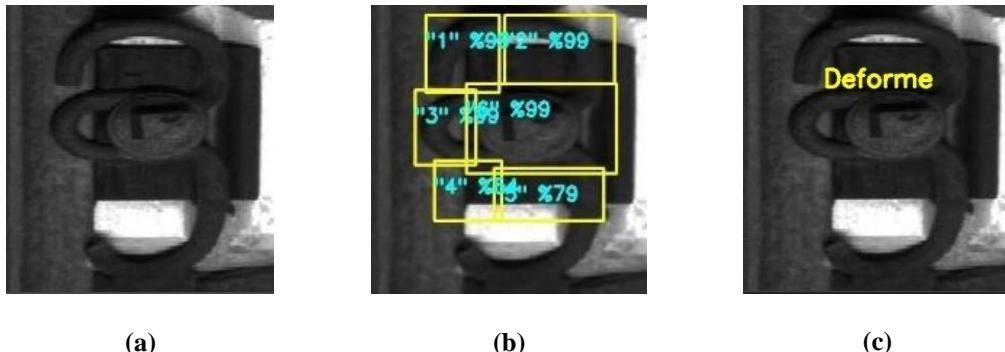
Şekil 12.a'da ise bağlantı elemanı yerinde değildir. Bu nedenle, sadece üç parçanın güven değeri bulunmaktadır. Eksik parçalar %0 olarak değerlendirilmektedir. Eksik parçaların %0 olarak değerlendirilmesi sonuç yüzdesinin değerini düşürmektedir. Şekil 12.d'de görüldüğü gibi parçanın sağlık durumunun yüzde değeri %45'ten düşük olduğu için eksik olarak nitelendirilmiştir. Nitelendirme sonucu Şekil 12.c'de gösterilmiştir.





(d)

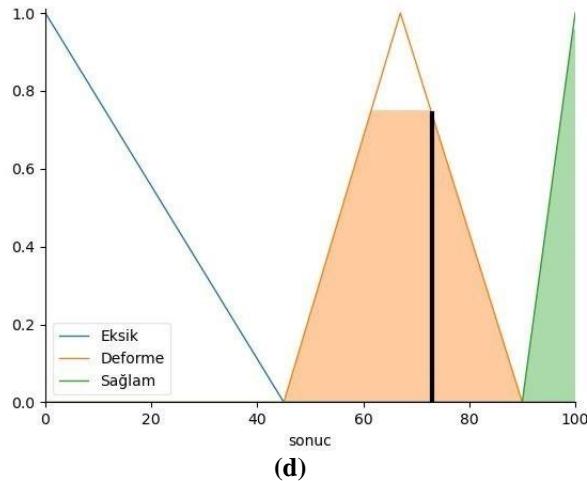
Şekil 10. Sağlam bağlantı elemanı için elde edilen sonuçlar (a) Giriş görüntüsü, (b) YOLOv4 çıktısı, (c) Sonuç (d) Sonuç grafiği



(a)

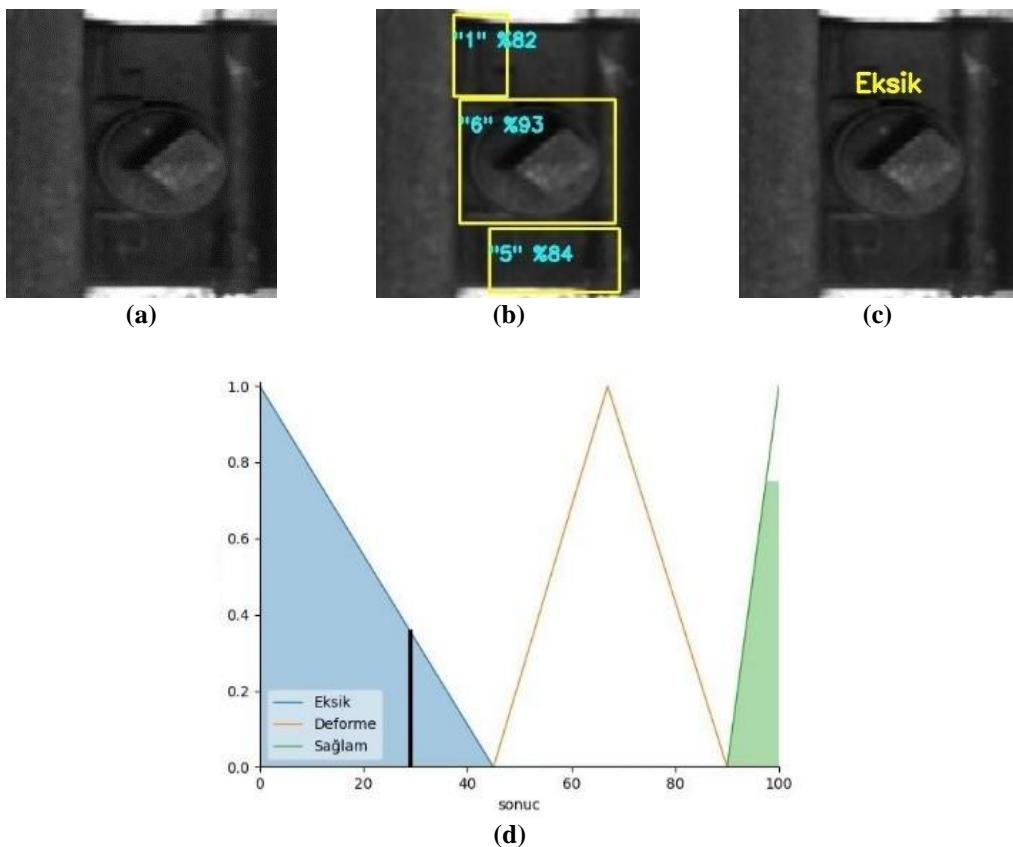
(b)

(c)



(d)

Şekil 11. Deforme bağlantı elemanı için elde edilen sonuçlar (a) Giriş görüntüsü, (b) YOLOv4 çıktısı, (c) Sonuç (d) Sonuç grafiği



Şekil 12. Eksik bağlantı elemanı için elde edilen sonuçlar (a) Giriş görüntüsü, (b) YOLOv4 çıktısı, (c) Sonuç (d) Sonuç grafiği

Yapılan çalışmada, tahmin başarı ölçütü için karmaşıklık matrisi kullanılmıştır. Karmaşıklık matrisi Tablo 2’de verilen parametrelerden oluşmaktadır.

Tablo 2. Karmaşıklık matrisi ölçüm değerleri için parametreler

Parametre	Açıklama
Doğru Pozitif (DP)	Gerçek sonuç sağlam olup sağlam olarak tahmin edilenler
Doğru Negatif (DN)	Gerçek sonuç deform olup deform olarak tahmin edilenler
Yanlış Pozitif (YP)	Gerçek sonuç deform olup sağlam olarak tahmin edilenler
Yanlış Negatif(YN)	Gerçek sonuç sağlam olup deform olarak tahmin edilenler

Sınıflandırma sonuçlarını değerlendirmek için dört metrik ve kullanılmıştır. Bu metrikler doğruluk(accuracy), hassasiyet(precision), geri çağrıma(recall) ve F1 değerleridir. Hesaplama için kullanılan formüller aşağıda verilmiştir.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$

$$Hassasiyet = \frac{DP}{DP + YP} \quad (4)$$

$$Geri Çağırma = \frac{DP}{DP + YN} \quad (5)$$

$$F1 = \frac{2 * \text{Geri Çağırma} * \text{Hassasiyet}}{\text{Geri Çağırma} + \text{Hassasiyet}} \quad (6)$$

Tablo 3. Bağlantı elemanı kusur tespiti için karmaşıklık matrisi
Tahmin edilen sınıf

Doğru sınıf	Sağlam	Kusurlu
	Sağlam	199
Kusurlu	2	198

Tablo 4. Dört ayrı ölçüt için performans değerleri

Doğruluk(%)	Hassasiyet(%)	Geri Çağırma(%)	F1 (%)
99,25	99	99,5	99,24

Önerilen algoritmayı test etmek için 200 adet sağlam, 200 adet kusurlu (eksik, deformé) olmak üzere 400 adet bağlantı elemanı görüntüsü kullanılmıştır. Tablo 3'te görüldüğü üzere önerilen algoritma 400 adet görüntüden 397'sini doğru, 3'ünü ise yanlış tespit etmiştir. Tablo 4'te dört ayrı ölçüt için doğruluk değerleri verilmiştir. Oranlar, önerilen algoritmanın bağlantı elemanı kusur tespiti için iyi performansa sahip olduğunu göstermektedir.

Önerilen yöntemin etkinliğini göstermek amacıyla literatürde bağlantı elemanı kusurlarının tespiti için geliştirilen yöntemler ile karşılaştırma yapılmıştır. Literatürde önerilen yöntemler kendi veri kümelerini paylaşmadıkları için kendi veri setimizde elde edilen sonuçlar ile diğer çalışmalarındaki sonuçlar doğruluk açısından karşılaştırılmıştır. Karşılaştırma olasılık tabanlı Yapısal Konu Modeli (YKM)[11] ve K-en Yakın Komşu tabanlı Şablon Eşleştirme(KYK-ŞE)[12] gibi bilgisayar görmesi teknikleri ve Hibrit YoloV4[18] ve Faster-RCNN[19] modelini kullanan derin öğrenme yöntemlerini içermektedir. Karşılaştırma sonuçları Tablo 5'te verilmiştir.

Tablo 5. Bağlantı elemanı için farklı kusur tespit yöntemleri ile karşılaştırma sonuçları

Referans	Yöntem	Örnek sayısı	Doğruluk (%)
[11]	YKM	4204	81,90
[12]	KYK-ŞE	6063	86,26
[18]	Hibrit YoloV4	1000	90,80
[19]	Faster-RCNN	634	96,50
Önerilen yöntem	YoloV4-Bulanık Mantık	400	99,24

Tablo 5'te verilen performans değerlendirmeleri göz önüne alındığında önerilen yöntemin daha iyi bir performansa sahip olduğu söylenebilir. Hibrit YoloV4[18] ve Faster-RCNN[19] kullanan yöntemlerin performansı bağlantı elemanın tam görünmesine bağlıdır. Bağlantı elemanın bir kısmı veya temamı eksik olduğunda iki yöntemin de tespit oranı düşmektedir. YKM[11] ve KYK-ŞE[12] kullanan iki yöntemde de görüntü boyutuna göre bazı öne parametrelerin ayarlanması gerekmektedir. Bu çalışmada önerilen yöntem bağlantı elemanın tamamı veya bir kısmı eksik olsa bile bağlantı elemanın yerini tespit etmektedir. Tespit işlemi yapıldıktan sonra karar verme

sürecinde kullanılan bulanık mantık sistemi kusurun derecesini belirlemektedir. Bu açıdan hem bağlantı elemanın tespiti için hem de kusur tespiti için daha sağlam bir model önerilmiştir.

4. Sonuç

Bu çalışmada, demiryolundan toplanan görüntülerden eksik bağlantı elemanları veya bağlantı elemanlarında bulunan kırıklar gibi anormalliklerin tespiti için YOLOv4 ve bulanık mantık yapısına dayanan bir bilgisayarla görme yaklaşımı önerilmektedir. Eğitim işleminde 2100 adet bağlantı elemanı kullanılarak eğitme işlemi yapılmıştır. Veri seti etiketleme işlemi için 6 bölge belirlenmiştir. Bu bölgeler seçilirken bölgelerin benzersiz olması sağlanmıştır. Bu yöntem ile bölgesel hata tespit oranının artması sağlanmıştır.

YOLOv4 algoritması kullanılarak demiryolundan toplanan görüntülerde bulunan bağlantı elemanlarının altı farklı bölümü için güven değeri elde edilmiştir. Elde edilen güven değerleri, oluşturulan altı girişli tek çıkışlı bulanık mantık yapısına giriş olarak verilerek bağlantı elemanın durumu hakkında bilgi elde edilmiştir. Yapılan testler, önerilen algoritmanın kusur tespitini tahmin etmede iyi sonuçlar verdiği göstermektedir. Başarı kriteri olarak doğruluk, hassasiyet, geri çağrıma ve F1 skor gibi kriterler kullanılmıştır. Test sonucunda bağlantı elemanlarının durumu %99.25 doğruluk oranı ile elde edilmiştir. Ölçüm sonuçları önerilen algoritmanın kusurlu bağlantı elemanlarının tespitinde yüksek başarım oranına sahip olduğunu göstermektedir.

Teşekkür

Bu çalışma, 120E097 numaralı TÜBİTAK projesi tarafından desteklenmiştir.

Kaynakça

- [1] Xu, T., Wang, G., Wang, H., Yuan, T., & Zhong, Z. (2016), “Gap measurement of point machine using adaptive wavelet threshold and mathematical morphology,” *Sensors*, 16(12), 2006.
- [2] Bokhman, E. D., Boronachin, A. M., Filatov, Y. V., Larionov, D. Y., Podgornaya, L. N., Shalymov, R. V., & Zuzev, G. N. (2014, September). “Optical-inertial system for railway track diagnostics,” In *2014 DGON Inertial Sensors and Systems (ISS)* (pp. 1-17). IEEE.
- [3] Ng, A. K., Martua, L., & Sun, G. (2019, September), “Dynamic modelling and acceleration signal analysis of rail surface defects for enhanced rail condition monitoring and diagnosis,” In *2019 4th International Conference on Intelligent Transportation Engineering (ICITE)* (pp. 69-73). IEEE.
- [4] 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.
- [5] Marino, F., Distante, A., Mazzeo, P. L., & Stella, E. (2007), “A real-time visual inspection system for railway maintenance: automatic hexagonal-headed bolts detection,” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 37(3), 418-428.
- [6] Alippi, C., Casagrande, E., Scotti, F., & Piuri, V. (2000), “Composite real-time image processing for railways track profile measurement,” *IEEE Transactions on instrumentation and measurement*, 49(3), 559-564.
- [7] Yang, J., Tao, W., Liu, M., Zhang, Y., Zhang, H., & Zhao, H. (2011), “An efficient direction field-based method for the detection of fasteners on high-speed railways,” *Sensors*, 11(8), 7364-7381.
- [8] Yuan, X., Liu, B., & Chen, H. (2017, October), “Algorithm and program design for fastener locating and detection using wavelet transformation and template matching,” In *2017 IEEE 17th International Conference on Communication Technology (ICCT)* (pp. 1116-1121). IEEE.
- [9] De Ruvo, P., Distante, A., Stella, E., & Marino, F. (2009, November), “A GPU-based vision system for real time detection of fastening elements in railway inspection,” In *2009 16th IEEE International Conference on Image Processing (ICIP)* (pp. 2333-2336). IEEE.
- [10] Kocbek, S., & Gabrys, B. (2019, November), “Automated machine learning techniques in prognostics of railway track defects,” In *2019 International Conference on Data Mining Workshops (ICDMW)* (pp. 777-784). IEEE.

- [11] 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.
- [12] Dou, Y., Huang, Y., Li, Q., & Luo, S. (2014), "A fast template matching-based algorithm for railway bolts detection," *International Journal of Machine Learning and Cybernetics*, 5(6), 835-844.
- [13] Dong, B., Li, Q., Wang, J., Huang, W., Dai, P., & Wang, S. (2019, November), "An end-to-end abnormal fastener detection method based on data synthesis," In *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)* (pp. 149-156). IEEE.
- [14] Chen, J., Liu, Z., Wang, H., & Liu, K. (2017, October), "High-speed railway catenary components detection using the cascaded convolutional neural networks," In *2017 IEEE International Conference on Imaging Systems and Techniques (IST)* (pp. 1-6). IEEE.
- [15] Wei, X., Wei, D., Suo, D., Jia, L., & Li, Y. (2020), "Multi-target defect identification for railway track line based on image processing and improved YOLOv3 model," *IEEE Access*, 8, 61973-61988.
- [16] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015), "You only look once: Unified, real-time object detection," *arXiv 2015. arXiv preprint arXiv:1506.02640*.
- [17] Xu, X., Lei, Y., & Yang, F. (2018), "Railway subgrade defect automatic recognition method based on improved faster R-CNN," *Scientific Programming*, 2018.
- [18] Guo, F., Qian, Y., & Shi, Y. (2021), "Real-time railroad track components inspection based on the improved YOLOv4 framework," *Automation in Construction*, 125, 103596.
- [19] 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.
- [20] Wang, C. Y., Liao, H. Y. M., Wu, Y. H., Chen, P. Y., Hsieh, J. W., & Yeh, I. H. (2020), "CSPNet: A new backbone that can enhance learning capability of CNN," In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops* (pp. 390-391).
- [21] Woo, S., Park, J., Lee, J. Y., & Kweon, I. S. (2018), "Cbam: Convolutional block attention module," In *Proceedings of the European conference on computer vision (ECCV)* (pp. 3-19).
- [22] He, K., Zhang, X., Ren, S., & Sun, J. (2015), "Spatial pyramid pooling in deep convolutional networks for visual recognition," *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- [23] Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018), "Path aggregation network for instance segmentation," In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8759-8768).
- [24] Boulkroune, A. (2016), "A fuzzy adaptive control approach for nonlinear systems with unknown control gain sign," *Neurocomputing*, 179, 318-325.
- [25] Zadeh, L. A. (1965). Zadeh, Fuzzy sets. *Inform Control*, 8, 338-353.

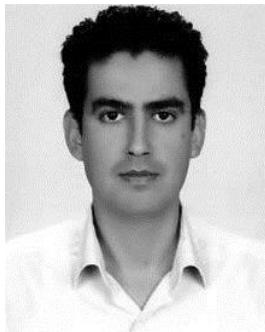
Özgeçmişler



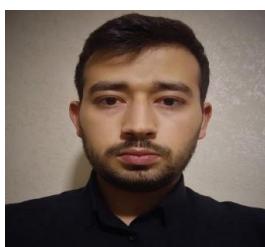
Emre GÜÇLÜ

1994'te Elazığ'da doğdu. İlk, orta ve lise öğrenimini Elazığ'da tamamladı. Necip Fazıl Kısakürek Anadolu Lisesi'ni bitirdikten sonra 2019 yılında Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği bölümünden mezun oldu. 2020 yılında Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim dalında yüksek lisans eğitimi başladı. Görüntü işleme ve yapay zeka alanlarında çalışmalarına devam etmektedir.

E-posta:emreguclu1367@gmail.com

**İlhan AYDIN**

1981 yılında Elazığ'da doğdu. Lisans ve Yüksek Lisans derecelerini Fırat Üniversitesi Bilgisayar Mühendisliğinde 2001 ve 2006 yıllarında aldı. Doktora derecesini 2011 yılında Fırat Üniversitesi, Elazığ Elektrik ve Elektronik Mühendisliği bölümünden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği bölümünde Doçent olarak görev yapmaktadır. Araştırma alanları arasında optimizasyon, gerçek zamanlı sistemler, hata teşhisleri ve durum izleme, sinyal ve görüntü işleme ve derin öğrenme bulunmaktadır.
E-posta: iaydin@firat.edu.tr

**Kadir ŞAHBAZ**

1995 Ankara doğumlu. İlk, orta ve lise öğrenimini Ankara'da tamamladı. Hacettepe Üniversitesi Bilgisayar Programcılığı mezunu ve Fırat Üniversitesi Bilgisayar Mühendisliği 4. Sınıf öğrencisi. Görüntü işleme ve derin öğrenme alanlarında çalışmaktadır.

E-posta: 66kadirsahbaz@gmail.com

**Erhan AKIN**

1963 yılında Erzincan'da doğdu. Elektrik mühendisliği alanında lisans ve yüksek lisans derecelerini ve doktora derecelerini sırasıyla 1984, 1987 ve 1994 yıllarında Fırat Üniversitesi'nden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği Profesörü olarak görev yapmaktadır. Başlıca araştırma alanları güç elektroniki, değişken hızlı AC sürücülerin dijital kontrolü, bulanık kontrol ve yazılımsal hesaplama teknikleridir.

E-posta: eakin@firat.edu.tr

**Mehmet KARAKÖSE**

Mehmet Karakose Fırat Üniversitesi Elektrik mühendisliği lisans derecesi, Bilgisayar Mühendisliği alanında yüksek lisans derecesi ve doktora derecelerini sırasıyla 1998, 2001 ve 2005 yıllarında almıştır. Halen Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Profesör olarak görev yapmaktadır. Araştırma ilgi alanları arasında bulanık sistemler, akıllı sistemler, simülasyon ve modelleme, arıza teşhisleri, bilgisayarla görme, demiryolu denetim sistemleri ve fotovoltaik sistemler yer almaktadır.

E-posta: mkarakose@firat.edu.tr

Beyanlar:

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Tüm yazarların eşit oranda katkısı olmuştur.