

**Pantograf Boynuz Hatalarının Derin Öğrenme ve Görüntü İşleme Teknikleri ile Tespiti**

Mahmut Ömer BAŞTÜRK^{*}, Veysel YÜKSEL, Yusuf Engin TETİK,
Mehmet YILMAZ, Mustafa GÜNER, Tolgahan KAYA

TÜBİTAK Raylı Ulaşım Teknolojileri Enstitüsü, Robotik ve Akıllı Sistemler Grubu, Kocaeli, Türkiye

**mahmut.basturk.d@tubitak.gov.tr.*

(Alınış/Received: 17.06.2022, Kabul/Accepted: 06.07.2022, Yayımlama/Published: 31.07.2022)

Öz: Görüntüler üzerinden hata ve anomalilerin otomatik tespiti, özellikle demiryolu taşımacılığı için kestirimci bakım uygulamalarında gün geçtikçe daha fazla yer bulmaktadır. Geleneksel bakım teknikleri, trenler için tam olarak güvenilemeyecek manuel çözümler içerirken; günümüzde görüntü işleme sayesinde daha sağlam çözümler üretilmektedir. Bu sayede bakım maliyetleri ve bakım süreleri de azalmaktadır. Trenler uzun mesafeler kat ettiğinden, trendeki sistemlerin yol boyunca zarar görmesi çok olasıdır. Hasar görme riski yüksek olan bu sistemlerden bir tanesi de pantograf-katener sistemidir. Pantografin katener ile temas eden bölgesi karbon şerittir ve katener sistemdeki elektriği trene iletmeye sebebiyle trene bağlı bileşenlerden en önemlilerinden bir tanesidir. Bu öneminden dolayı, karbon şeridi ağaç dalları gibi hasar verebilecek dış etkenlerden korumak için pantograf boynuzlarına ihtiyaç vardır. Karbon şerit yerine pantograf boynuzları hasar gördüğü için pantograf boynuzlarının bakıma ihtiyacının olup olmadığının bilinmesi önemlidir. Hasarlı boynuzların tespiti, görüntü işleme ve derin öğrenme tekniklerinden yararlanılarak otomatik olarak yapılabilir. Bu çalışmada, farklı çevresel koşullarda farklı hatalara sahip olan ve olmayan pantograf boynuzlarını içeren 34 adet simülasyon videosu oluşturulmuştur. Bu videolardan elde edilen kareler ayrı ayrı işlenmiştir. Temel görüntü işleme teknikleri sayesinde pantograf dışındaki arka plan nesneleri kaldırılmış, derin öğrenme modeli ile pantograf boynuz bölgeleri tespit edilmiş ve evrişimli sinir ağı sayesinde bir boynuzun hatalı olup olmadığı sınıflandırılmıştır. Oluşturulan metot ile bir pantograf boynuzunun hatalı veya sağlıklı olmasına %95,36 oranında doğru karar verilmektedir. Yüksek doğrulukla çalışan bu yeni yöntem, pantograf boynuz analizi üzerine literatüre önemli bir katkı sağlamaktadır.

Anahtar kelimeler: Derin öğrenme, Pantograf boynuzu, Görüntü işleme, Arka plan çıkarma, Sınıflandırma, Evrişimli Sinir Ağı

Detection of Pantograph Horn Defects Based on Deep Learning and Image Processing

Abstract: Automated anomaly and defect detection via images finds its place more and more in predictive maintenance applications, especially for rail transport. While traditional maintenance techniques include manual solutions that cannot be fully trusted for trains, today more robust solutions are produced thanks to image processing. In this way, maintenance costs and maintenance times are also reduced. Because trains travel long distances, it is quite possible for systems on the train to be damaged along the way. One of these systems with a high risk of damage is pantograph-catenary systems. The part of the pantograph that contacts the catenary is carbon strip which receives electricity from catenary and transmits it to the train. Therefore, pantograph horns are needed to protect the carbon strip from damaging external factors such as tree branches. It is important to know if the pantograph horns need maintenance or not since they are damaged instead of carbon strips. Detection of damaged horns can be realized using image processing and deep learning techniques. In this study, 34 simulation videos containing pantograph horns with and without defects in different environmental conditions were created. Obtained frames from these videos are processed separately. Thanks to image processing, background objects other than the pantograph were removed, pantograph horn regions were detected with the deep learning model, and the horn was classified as healthy or defected via convolutional neural network. With the created method, 95.36% correct decision is made whether a pantograph horn is faulty or healthy. This new method, which works with high accuracy, makes an important contribution to the literature on pantograph horn analysis.

Atıf için/Cite as: M.Ö. Baştürk, V. Yüksel, Y.E. Tetik, M. Yılmaz, M. Güner, T. Kaya "Pantograf boynuz hatalarının derin öğrenme ve görüntü işleme teknikleri ile tespiti," *Demiryolu Mühendisliği*, no. 16, pp. 102-115, July, 2022. doi: 10.47072/demiryolu.1132123

Keywords: Deep learning, Pantograph horn, Image processing, Background subtraction, Classification, Convolutional Neural Network

1. Giriş


Tren bileşenlerindeki arızaların erken tespiti ve ilgili parçalarda meydana gelmesi muhtemel daha büyük sorunların ortaya çıkmadan müdahale edilebilmesi kestirimci bakım açısından kritik bir uygulamadır. Trenlerde büyük bir soruna neden olabilecek en kritik bileşenlere örnek olarak pantograf verilebilir. Pantograflar elektriği trene iletmek için katener sistem ile temas eden yapılardır. Pantograf, içinde birkaç alt yapıdan oluşan genel bir isimdir. Bu çalışmada üzerinde durulan kısımlar daha çok pantograf karbon şeridi ve ana konu olan pantograf boynuzlarıdır. Katener telindeki elektrik, pantograf karbon şeridi ve katener telinin sürtünmesi yoluyla trene iletilir. Meydana gelen sürtünme sebebiyle karbon şerit üzerinde aşınmalar gerçekleşir ve bu aşınmaların boyutlarının çikartılması da başka bir önemli araştırma konusudur [1-3].

Tren seyahat ederken pantografin karbon şeridinin ağaç dallarından zarar görme riski çok yüksektir. Eğer karbon şerit çok fazla hasar görür ise katenerden trene giden elektrik kesintiye uğrayabilir. Bu durumu önlemek için pantograf boynuzları kullanılır. Pantograf boynuzları, pantografin her iki ucundaki kıvrımlı yapılardır ve karbon şeridi ağaç dalları gibi dış etkilerden korumak amacıyla pantografa yerleştirilirler. Pantograf boynuzuna temas eden dış etkiler, pantograf boynuzlarında eğilme ve kırılma gibi hasarlar oluşturabilmektedir. Bu nedenle, pantograf boynuzlarının incelenmesi, önleyici bakım adına bir gerekliliktir.

Pantograf boynuzlarının görüntü tabanlı incelenmesinden önce muayene işlemi; tren, istasyonda durduğunda görevli personelin trenin üzerine çıkıp göz ile muayene yapmasıyla gerçekleştirilir. Bu yöntemin dezavantajları, muayene işleminin yalnızca tren durduğunda gerçekleştirilebilmesi ve trenin çatısında yapılması sebebiyle görevli personelin hayatının riske atılmasıdır. Görüntü tabanlı yaklaşımlar, pantograf boynuzları için daha güvenli ve güvenilir sonuçlar üretebilmektedir. Ek olarak bu sistemlerin kurulumu da kolaydır [4]. Görüntü tabanlı yaklaşımda, katener sistem ile pantograf karbon şeridinin temas noktasının bulunması, pantograf muayenesi, pantograf arıza tespiti ve pantograf boynuz tespiti gibi farklı amaçlar için farklı yöntemler ve farklı algoritmalar kullanılmaktadır. Karaköse ve diğ. pantograf kontak şeritleri ile katener kontak tellerinin etkileşimi ile oluşan pantograf yüzeyindeki kontak noktası bölgelerini, görüntü işleme tabanlı algoritmalar ile izlenerek arızaların tespitini gerçekleştirmişlerdir. Bu çalışmada pantograf ve katener telinin algılanmasında kenar tespiti ve Hough dönüşümü tekniklerini kullanmışlardır [5]. Dong Li, pantograf aşınmasının temassız izlenmesi için etkili bir stereo tabanlı yöntem önermiştir. Bu çalışmada pantograf karbon şerit ve boynuzdaki bozuklukları nokta-bulut karşılaştırma yöntemi ile tespit etmektedirler [6]. Yao ve diğ., pantograf aşınması ve duruş tespiti için görüntü tabanlı bir çevrimiçi izleme sistemi gerçekleştirmiştir. Bu sistemde de pantograf boynuzları Hough dönüşüm algoritması yardımıyla tespit edilmiştir [7]. Yaman ve diğ. pantograf katener sistemlerinden alınan görüntüler kullanılarak pantograf sisteminin geometrik modelini oluşturup, hangi tür pantograf olduğu tespit etmişlerdir. Bu çalışmada pantograf tespiti için Hough dönüşümü ve bulanık mantık tekniklerini birlikte kullanmışlardır [8]. Benzer şekilde Karaköse ve diğ., pantograf katener sistemlerde görüntü işleme tekniklerini kullanarak ark tespitini yapmışlardır [9]. Bu çalışmada kenar bulma algoritmalarından eşikleme metodlarına kadar birçok yöntem kullanmışlardır. Görüldüğü üzere pantograf-katener sistemleri ile ilgili yapılan bu çalışmalarda temel görüntü işleme tekniklerinden derin öğrenmeye kadar birçok farklı metod geliştirilmiştir. Ancak, son araştırmalar, derin öğrenme ve makine öğrenimi modellerinin daha sağlam olduğunu ve güvenilir sonuçlar ürettiğini göstermektedir. Zhang ve diğ., Derin Evrimsel Ağ'a dayalı sağlam bir pantograf-katener etkileşim durumu izleme sistemi geliştirmişlerdir [10]. Chang ve diğ., pantograf boynuzlarının tespit edilmesi için SSD obje algılama yöntemini kullanmışlardır [11]. Shen ve diğ. tren açık havada uzun süreli operasyonda yüksek hız ve istikrarlı durum analizi gerçekleştirmek için parametre uyarlamasına dayalı pantograf ve katener sistem

durumunun çevrimiçi algılanması üzerine çalışmışlardır. Bu çalışmada pantograf boynuzlarının algılanması için RefineDet makine öğrenimi modeli kullanılmıştır [12].

Bu çalışma, gerçekleştirilmesi planlanan pantograf denetleme sisteminin simülasyon ortamında oluşturulup pantograf boynuzunun sağlıklı veya kusurlu olmasına nasıl karar verileceğini incelemek adına yapılmıştır. Kamera açısı ve kameranın pantograf boynuzuna olan mesafesi gerçekte kurulabilecek bir sistem için hesaplanmış ve Unity’de simüle edilmiştir. Bu çalışmada maksimum 30 km/saat hız ile seyahat eden trenlerin pantograf boynuzlarının muayenesi planlanmıştır. Pantograf denetleme sistemi seçilen bir tren istasyonunun giriş veya çıkışına konulabilecektir. Bu sistem ile belirtilen hızda ilerleyen trenler için pantograf boynuzlarındaki hataların tespitinin yapılabilmesi mümkün olacaktır. Yüksek hızlarda muayene gereken sistemlerde kamera ve uygun lens seçimi büyük önem arz etmektedir. Yüksek hızlarda çalışan sistemlerin muayenesinde veri toplama için kullanılan kameraların saniye başına toplayabileceği görüntü sayısı (FPS) yüksek olmalıdır. Bu çalışmada kullanılan kamera, açılı yerleştirilmiş ve pantograf sistemini yukardan görecektir şekilde ayarlanmıştır. Kamera, pantograf sisteminden dikeyde 1 metre yüksekliğe, 10 derece açı ile yerleştirilmiştir, bu sayede daha büyük bir görüş alanı elde edilmiştir. Şekil 1’de kamera görüş açısı ve simülasyon ortamında gerçekleştirilen sistemin temsili görülebilir.



Şekil 1. Kamera ve görüş alanı

Açılı bir şekilde yerleştirilen kamera sayesinde oluşturulacak bu büyük görüş alanında trenin geçişi esnasında 1000 kare toplanması hedeflenmiştir. Bu çalışmada 2295 saniye başına kare hız ve 1920x1080 çözünürlükte bir kamera kullanılmıştır. 30 km/saat hızda giden bir tren için 2295 saniye başına kare hızda çalışan bir kamera kullanıldığında 1000 kare toplayabilmek için olması gereken görüş alanı Denklem 1’deki gibi hesaplanıp 3,63 m olması gerektiği bulunmuştur. Burada V tren hızını, FS analiz için hedeflenen kare sayısını, FPS kamera görüntü toplama hızını ve Y görüş alanını temsil etmektedir.

$$Y = \frac{V \left(\frac{\text{metre}}{\text{saniye}} \right) FS}{FPS} \quad (1)$$

Bu görüş alanını elde edebilmek için kameranın koyulması gereken açı Denklem 2’deki gibi hesaplanmıştır.

$$\beta = \frac{S}{2F} \quad (2)$$

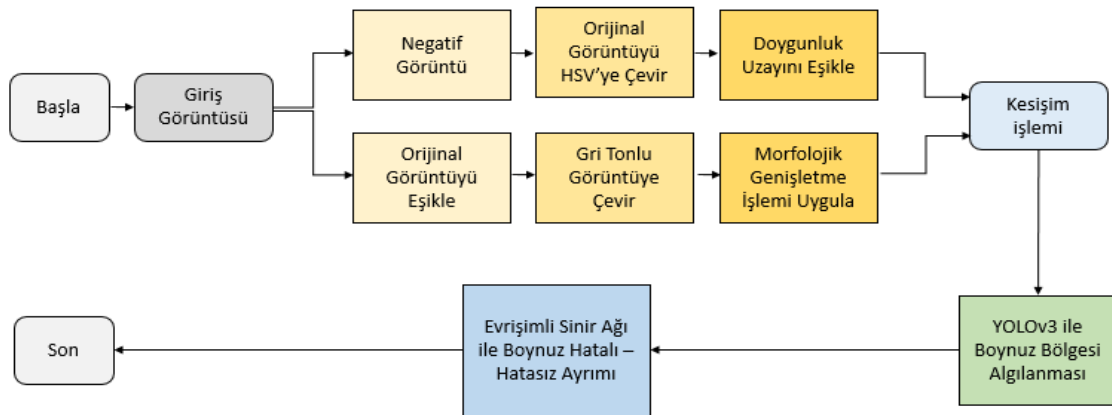
$$a = \tan \left(\sqrt{\frac{\frac{y}{h} - 2\beta}{2\beta + \frac{y}{h}\beta^2}} \right) - \tan^{-1}(\beta) \quad (3)$$

Burada α kamera açısını, Y görüş alanını, h kameranın pantograftan yüksekliğini, S kamera sensör genişliğini ve F odak uzaklığını gösterir.

Bu çalışmada, bir pantograf denetleme sistemi fiziksel dünyada gerçekleşmeden önce aynı sistemin simülasyon ortamında gerçekleştirilmesi yapılmış ve sağlıklı ve kusurlu olarak hazırlanan farklı pantograf boynuzlarına ait videoların görüntü işleme, derin öğrenme ve Evrişimli Sinir Ağları (ESA) modellerinin kademeli olarak kullanımı ile pantograf boynuzunun sağlıklı veya kusurlu şeklinde sınıflandırılabilmesi için bir yöntem önerilmiştir. Önerilen yöntemin görüntü işleme ile arka plan çıkarma, önceden eğitilmiş bir YOLOv3[10] modeli ile pantograf boynuz bölgelerinin tespiti ve tasarlanan bir ESA modeli ile pantograf boynuzlarının sağlıklı veya kusurlu olarak sınıflandırılması olmak üzere üç aşaması vardır. Bu makalenin geri kalanı şu şekilde organize edilmiştir: Kısım II, önerilen yöntemin detaylı açıklaması; Kısım III, simülasyon videolarında koşturulan yöntemin sonuçları; Kısım IV, sonuçların yorumlanması ve değerlendirme şeklindedir.

2. Metot

Pantografin ve arka planın bütün olarak görülebildiği ham giriş görüntüleri incelenerek öncelikle herhangi bir ön işlem yapılmadan pantograf boynuzlarının tespiti yapılmaya çalışılmıştır. Pantograf boynuzunu bütün resimde öne çıkaran iki temel ayırt edici öznelik bulunmaktadır: siyaha yakın bir renk tonunun olması ve pantografin iki ucunda kıvrımlı yapıda olması. İlk denemelerde pantograf boynuz tespiti üzerine yoğunlaşıp bir sonuç üretmek üzere odaklanılması gereken noktalar olarak bu özneliklerin bulunması amaçlanmıştır. Bu aşamada SIFT[14] ile söz konusu ayırt edici özelliklerin tespiti ile nesne tespiti yapılmaya çalışılmıştır. Bu deneme arka planın çok karmaşık olması sebebi ile başarılı olmamıştır. Benzer şekilde ham görüntü üzerinde YOLOv3 ve Unet[15] gibi nesne tespitinde sıklıkla kullanılan ESA tabanlı derin öğrenme modelleri koşturulmuş olmasına rağmen boynuz bölgeleri istenilen oranda başarıyla tespit edilememiştir. Bu nedenle, pantograftan arka plan görüntüsünün çıkarılması denenmiştir ve bu çalışmada önerilen yöntem bu temeller üzerine kurulmuştur. Önerilen yöntem, arka plan çıkarma (görüntü işleme), tespit (derin öğrenme) ve karar (evrişimli sinir ağı) olmak üzere üç aşamadan oluşmaktadır. Önerilen yöntemle ait akış diyagramı Şekil 2’de görülebilir.



Şekil 2. Algoritma akış diyagramı

2.1. Veri seti

Geliştirilen algoritmaları çalıştırmak ve test etmek amacıyla Unity programında simülasyon modelleri ve bu modellerden 34 adet simülasyon veri seti oluşturulmuştur. Simülasyon modellerinde TCDD'nin sıklıkla kullandığı E68000 elektrikli lokomotiflerinde kullanılan, Tip 1600 pantograf modeli kullanılmıştır. Tip 1600 pantograf modeli, hızlı tren ve metro hatları dışında kalan “ana hat” diye ifade edilen hatlarda kullanılan modellerden biridir. Simülasyonlarda, tren yaklaşık 30 km/h saat hızla ilerlerken, pantograf, kendisinden yaklaşık 1 metre yüksekliğe yerleştirilmiş ve düşeyle 45 derece açı yapan 2295MP bir kamera ile gözlemlenmiştir. Simülasyon ortamı, geliştirilen algoritmaların çalışırılığının görülebilmesi amacıyla farklı çevresel koşulları (güneş açısı, zemin vs.) içerecek şekilde oluşturulmuştur. Daha sonra pantograf boynuzlarında en sık görülen hatalara bakılarak Blender üç boyutlu yapı modelleme programında pantograf boynuzlarında bükülme ve kırılma gibi farklı türde kusurlar oluşturulmuştur. Son olarak, videolar, sağlam bir veri seti oluşturmak için rastgele ortamlar ve farklı kusurların kombinasyonu ile kaydedilmiştir. Farklı pantograf boynuz kusurlarına sahip simülasyon videolarından toplanan görüntü örnekleri Şekil 3'te görülebilir.




Şekil 3. Simülasyon verilerinden alınan farklı görüntü örnekleri

2.2. Aşama I: Arka plan çıkarma – görüntü işleme


Arka plan çıkarma aşamasında, pantografin bütün olarak arka plandan ayrıştırılabilmesi için bir yöntem geliştirilmiştir. Bu kısımda yalnızca temel görüntü işleme teknikleri kullanılmıştır. Pantografin renk özneliğine odaklanılarak arka planı çıkarılmış görüntü elde edilmiştir. Başarılı bir arka plan çıkarılmış görüntü elde etmek için aynı orijinal giriş görüntüsü Şekil 2'deki algoritma akış diyagramında da görülebileceği gibi iki farklı kolda farklı işlemler uygulanarak işlenmiştir. Daha sonra iki farklı kolda elde edilen çıktı görüntülerinin kesişimi alınarak birkaç görüntü dışında yalnızca pantografin görülebildiği çıktı görüntüsü elde edilmiştir.

İlk koldaki görüntü işleme kısmında, orijinal görüntünün negatifi alınır ve kırmızı-yeşil-mavi (*eng. RGB*) renk uzayından ton-doygunluk-değer (*eng. HSV*) renk uzayına geçilir. Doymunluk-ton-değer görüntüleri ayrı ayrı incelendiğinde doymunluk görüntüsünün siyah renkli cisimlerin oldukça iyi ayrıştırıldığı anlaşılmıştır. Bu sebeple doymunluk görüntüsünde siyah tonlara eşikleme uygulanarak ilk kola ait çıktı görüntüsü elde edilmiştir. İlk görüntü işleme koluna ait her bir adımdaki çıktı görüntüsü ise Şekil 4'te görülebilir.




Şekil 4. İlk görüntü işleme kısmındaki çıktı görüntüleri a) Orijinal görüntü b) Negatif görüntü c) HSV renk uzayı görüntüsü d) S uzayı görüntüsü e) Eşiklenmiş görüntü

İkinci koldaki görüntü işleme kısmında, orijinal görüntü direkt olarak eşiklenir. Buradaki eşiklemenin amacı çok parlak renkli olan nesnelere görüntüden kaldırmaktır. Daha sonra eşiklenmiş kırmızı-yeşil-mavi renkli görüntü gri seviyeli görüntüye çevrilir. Eşikleme sonrası bazı objelerde yerel boşluklar oluşabilmektedir. Bu sebeple morfolojik genişleme işlemi uygulanmıştır. Bu işlemler sonrasında daha çok parlak renkli objeler görüntüden kaldırılmış ve pantografin bütünü büyük oranda elde edilmiştir. İkinci kolda yapılan her bir işlem sonrası elde edilen çıktı görüntüleri Şekil 5'te görülebilir. Şekil 6'da ise en son morfolojik genişleme işlemi sonrası elde edilen görüntü görülebilir.



Şekil 5. İkinci görüntü işleme kısmındaki çıktı görüntüleri a) Orijinal görüntü b) Eşiklenmiş RGB görüntü c) Gri seviyeye dönüştürülmüş görüntü



Şekil 6. Genişletme işlemi çıktısı

Birinci ve ikinci kısımdaki görüntü işleme adımları tamamlandığında, oluşan iki adet çıktı görüntüsünün kesişimi alınarak tek bir görüntü oluşturulur. Bu görüntüde pantografin bütün hali arka plandan ayrıştırılmış şekilde elde edilir. Bununla birlikte bazı arka plan nesnelere de görüntüler şeklinde gözükmetedir. Elde edilen çıktı görüntüsü Şekil 7’de görülebilir.




Şekil 7. Kesişimi alınmış görüntü

2.3. Aşama II: Tespit – derin öğrenme

Tespit aşamasında, arka plan çıkarma işlemi sonrasında oluşturulan çıktı görüntüsü YOLOv3 derin öğrenme modeline verilerek boynuz bölgelerinin tespiti sağlanır. Bu aşamada sağlıklı ve kusurlu ayrımı yapmaksızın pantograf boynuzlarının hepsinin bulunması amaçlanmaktadır. Modelin eğitimi için simülasyon videolarındaki görüntüler arka planları çıkartılmış şekilde ayrı olarak kaydedilmiştir. Bu görüntüler üzerinde yalnızca boynuz bölgelerinin olduğu kısımlar sınırlayıcı kutular içerisinde alınarak etiketlenmiştir. Bu aşamada tek sınıflı bir nesne tespit işlemi yapılmıştır. Eğitimde toplamda hatalı ve hatasız olacak şekilde 6996 adet görüntü üzerinde eğitim yapılmıştır. Eğitim 620. iterasyonda erken sonlandırma ile durdurulmuş ve model ortalama kayıp değeri yüzde 0,24 olarak sonuçlanmıştır.

Doğrulama işlemi için 870 adet görüntü kullanılmış ve model 870 adet görüntü ile test edilmiştir. Model başarıyla eğitilmiş ve test görüntülerindeki pantograf boynuz bölgelerini ayırt edebilmiştir. Aşağıdaki Şekil 8’de örnek bir tespit algoritması çıktısı görülebilir.



Şekil 8. YOLOv3 ile tespit edilen boynuzlar

2.4. Aşama III: Karar – Evrişimli Sinir Ağı (ESA)

Karar aşamasında pantografin sağlıklı veya kusurlu şeklinde sınıflandırılması gerçekleştirilir. Tespit aşaması sonucunda bir simülasyon videosundaki her bir görüntü üzerindeki iki adet pantograf boynuzu tespit edildiğinden bahsedilmiştir. Bulunan pantograf boynuzları sınırlayıcı kutular ile konumlandırılır. Bu konumlar orijinal görüntü üzerinden bulunur ve yalnızca boynuzların olduğu görüntüler elde edilir. YOLOv3 ile tespit edilen sağ ve sol pantograf boynuzlarına ait kırmızı-yeşil-mavi renkli görüntüler ayrı bir dosya üzerinde kaydedilmiştir. Aşağıdaki Şekil 9’da örnek çıktılar görülebilir.



Şekil 9. Tespit edilen pantograf boynuzları


Bu işlem sonucunda toplamda 7804 adet boynuz tespit edilmiştir. Bu boynuzlar hatalı boynuz simülasyonlarından gelenler için hatalı boynuzlar klasöründe; hatasız boynuz simülasyonlarından gelenler için hatasız boynuzlar klasöründe tutulmuştur. Buradan da anlaşılacağı üzere iki sınıflı bir problem elde edilmiştir. Toplamda elde edilen 7804 adet boynuz görüntüsünün %10’u doğrulama ve %10’u test veri setlerini oluşturmak için ayrıştırılmıştır. Buna göre 6244 adet eğitim, 780 adet doğrulama ve 780 adet test verisi elde edilmiştir. Eğitim verilerindeki 6244 adet boynuz görüntüsü üzerinde veri artırma işlemi gerçekleştirilmiş ve 130994 adet eğitim verisi oluşturulmuştur.

Boynuzların sınıflandırılabilmesi için ESA tabanlı bir derin öğrenme modeli oluşturulmuştur. ESA, derin öğrenme modellerinde sıklıkla kullanılan, çok küçük özniteliklerden çok büyük özniteliklere kadar bütün öznitelikleri adaptif şekilde öğrenebilen bir algoritmadır. Genel olarak bir ESA algoritması bir giriş katmanı, birkaç adet evrişim ve ortaklama katmanlarından, tam bağlantılı katmanlardan ve bir çıkış katmanından oluşur. ESA algoritması sayesinde görüntüler üzerinden nesne tespiti yapmak mümkündür. Bu çalışmada ESA ile bir pantograf boynuzunun hatalı veya sağlıklı olmasının sınıflandırılması gerçekleştirilmiştir.

Elde edilen eğitim verilerindeki boynuz görüntülerinden yararlı öznitelikler çıkartmak için evrişim katmanları kullanılır. Bu katmanlarda öznitelik çıkarma işlemi belirlenen filtre (kernel) sayısı kadar yapılır. Evrişim katmanlarının derinliği kullanılan evrişim filtre sayısı ile tanımlanır. Görüntülerdeki öznitelikler, filtrelerin orijinal görüntü ile korelasyonunun alınması sonucu elde edilir. Elde edilen korelasyon görüntüsü doğrusal olmayan bir fonksiyon ile çarpılır. Sonuçta ise öznitelik haritası verilen bir katman elde edilir. Ortaklama katmanları evrişim katmanlarından

sonra kullanılır ve elde edilen öznelik haritalarını birçok dikdörtgen kernel oluşturacak şekilde bölerek alt örnekleme yapar. Ortaklama işlemi, öznelik haritasının boyutunu küçültme olarak da bilinir ve kernel'lerin maksimum değerini bularak yapılabilir. Bu işleme maksimum ortaklama denirken benzer şekilde kernel'lerin ortalama değerini bularak ortalama ortaklama yapılabilir. Ortaklama işlemi sayesinde boyut küçültmesi sağlandığı için işlem süresi düşer ve modelin aşırı uyum (*eng. Overfitting*) olma ihtimalini azaltır. ESA mimarisinin son aşamasında tam bağlantılı (*eng. Fully-connected*) katmanlar bulunur. Bu katmanlarda daha önceden elde edilmiş 2 boyutlu öznelik haritaları yan yana eklenerek 1 boyutlu vektöre dönüştürülür. Elde edilen 1 boyutlu vektör üzerinde daha sonrasında bir yapay sinir ağı uygulanarak sınıflandırma veya regresyon işlemi gerçekleştirilir. En son katmanda sınıflandırma işlemi iki sınıflı bir problem olmasından dolayı "ikili çapraz entropi" (*eng. Binary Cross Entropy*) kullanılmış ve sınıflandırma işlemi gerçekleştirilmiştir.

Bu çalışmada eğitim seti için ayrılmış olan pantograf boynuzlarının sağlıklı veya kusurlu olarak sınıflandırılması için bir ESA modeli geliştirilmiştir. Oluşturulan model Şekil 10'da görülebilir.




Şekil 10. Oluşturulan evrişimli sinir ağı yapısı

ESA modelinin girişine verilmeden önce bütün görüntüler aynı boyutta olmaları için 95x95 olarak ölçeklendirilmiştir. Önerilen model birkaç evrişim katman ve buna bağlı ortaklama katmandan oluşmaktadır. En sonda ise 1 adet tam bağlantılı katman ile sınıflandırma yapılır. Kurulan modelin ilk evrişim katmanında 16 adet filtre 3x3 boyutunda kernel boyutuyla hesaplanır. Dolgu (*eng. Padding*) "aynı" (*eng. Same*) olarak seçilmiştir. Bunun anlamı evrişim işlemi sonrasında orijinal resmin boyutu aynı kalacaktır. Böylelikle giriş görüntüsündeki bütün elemanlara filtre uygulanmış olacaktır. Evrişim işlemi sonucunda elde edilen çıkış hala doğrusal bir davranış sergilemektedir. Doğrusal olmayan hale getirmek için görüntüye her evrişim işlemi ile birlikte doğrultulmuş lineer birim aktivasyon fonksiyonu (*eng. ReLU*) uygulanır. Benzer şekilde her evrişim işleminden sonra 2x2 boyutunda maksimum ortaklama uygulanır. En son evrişim ve maksimum ortaklama işleminden sonra bir adet tam bağlantı katmanı bulunmaktadır. Elde edilen çıktılar düzleştirilerek sınıflandırma işlemi için uygun bir vektör haline getirilir. En son katmanda ise elde edilen vektör, bir sigmoid fonksiyonuna verilerek giriş görüntüsünün hangi sınıfa ait olduğu en yüksek olasılık değerine göre belirlenir.

3. Bulgular

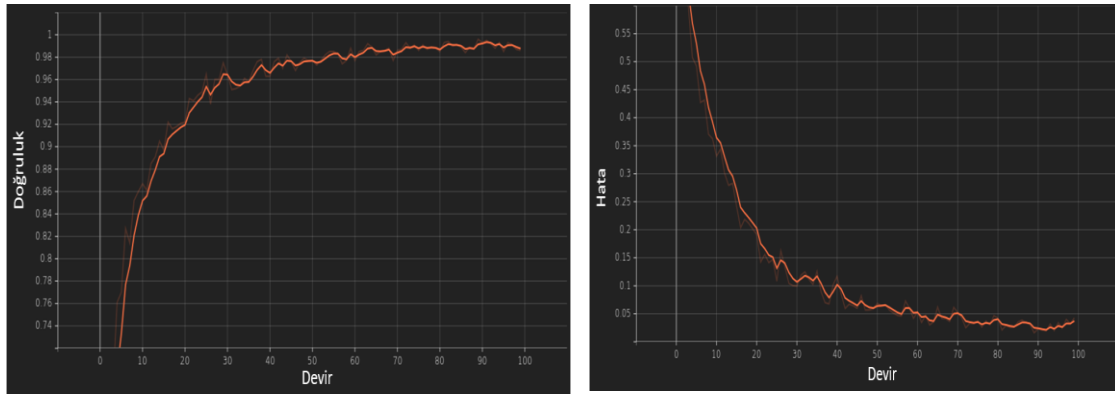
Bu çalışmada önerilen yöntem, görüntü işleme ile arka plan nesnelerinin çıkarılması ve ESA tabanlı modeller ile bir pantograf boynuzunun tespit edilip sağlıklı veya kusurlu olduğuna karar vermek için kullanılmaktadır. Derin öğrenme adımıdaki YOLOv3 modeli Darknet53 çerçevesiyle uygulanmıştır. Karar aşamasındaki tasarlanan ESA modeli ise Tensorflow çerçevesiyle uygulanmıştır. İki model de NVIDIA Tesla K80 ekran kartı kullanılarak eğitilmiştir.

Tespit aşamasında kullanılan YOLOv3 modelinde 620 devir yapılmıştır ve öğrenme oranı 0.001 olarak belirlenmiştir. Eğitim işlemi sonucunda oluşan devir-doğruluk ve devir-hata oranları Şekil 11'de verilmiştir.



Şekil 11. Tespit aşamasındaki YOLOv3 modeline ait sonuçlar a) Devir – Doğruluk b) Devir – Kayıp

Karar aşamasındaki modelde optimizasyon yöntemi olarak Adam Optimizer[16] kullanılmıştır ve öğrenme oranı 0.001 olarak belirlenmiştir. İki sınıflı problemde öğrenme aşamasında 100 devir yapılmıştır. Eğitim işlemi sonucunda oluşan devir-doğruluk ve devir-kayıp oranları Şekil 12’de verilmiştir. Geliştirilen model diğer tipik ESA modelleri ile karşılaştırdığında daha iyi sonuç vermektedir. Tablo 1’deki sonuçlardan çıkarılabileceği gibi LeNet-5 mimarisi bu uygulama için çok basit, AlexNet mimarisi ise karmaşıktır.



Şekil 12. Karar aşamasındaki ESA modeline ait sonuçlar a) Devir – Doğruluk b) Devir – Kayıp

Tablo 1. Önerilen yöntemin diğer ESA algoritmalarına göre performans karşılaştırması

| | Geliştirilen Model | LeNet-5 | AlexNet |
|--------------|--------------------|---------|---------|
| Doğruluk (%) | 94,26 | 72 | 81 |
| Kayıp(%) | 0,02 | 0,40 | 0,13 |

Karar aşamasında oluşturulan model bir pantograf boynuzunun hatalı olup olmamasına karar verir. Burada ikili bir sınıflandırma olduğu için sigmoid aktivasyon fonksiyonu kullanılmaktadır. Modele verilen görüntü çıktısı eğer 0 değerine sahip ise hatalı, 1 değerine sahip ise sağlam pantograf boynuzu anlamına gelmektedir. Test görüntüleri üzerindeki eşleştirmelerden elde edilen karmaşıklık matrisi sonucu Şekil 13’te verilmiştir.

| | | | |
|--------|----------|----------|---------|
| Gerçek | Sağlıklı | 329 | 32 |
| | Kusurlu | 20 | 742 |
| | | Sağlıklı | Kusurlu |
| | | Tahmin | |

Şekil 13. Karmaşıklık matrisi

Karmaşıklık matrisi doğruluk, duyarlılık, özgünlük ve F1 değerlerinin çıkarılması için kullanılan bir araçtır. Bu değerleri hesaplamak için kullanılan denklemler aşağıdaki şekilde sırasıyla verilmiştir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YN + YP + DN} \quad (4)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (5)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (6)$$

$$F1 = \frac{2DP}{2DP + YP + YN} \quad (7)$$

Tablo 2. Önerilen yöntemin performans sonuçları

| Doğruluk (%) | Kesinlik (%) | Duyarlılık (%) | F1 (%) |
|--------------|--------------|----------------|--------|
| 95,36 | 94,26 | 91,13 | 92,67 |

Önerilen yöntemin performans ölçütlerine göre sonuçları Tablo 2’de verilmiştir. Elde edilen sonuçları mukayese etmek amacıyla literatürde yapılan çalışmalar incelendiğinde literatürdeki çalışma sonuçlarının nicel olarak paylaşılmadığı görülmüştür. Bu çalışmalarda yalnızca pantograf boynuzlarında hata tespitinin yapılabildiğinden bahsedilmiştir. Kullanılan yöntemler ise çoğu çalışmada temel görüntü işleme tekniklerinin ötesine geçmemektedir. Bu çalışmada önerilen yöntem yapay zekâ tabanlı algoritmalar içermektedir. Bu sebeple farklı ortam şartlarında çalışabilen adaptif bir yöntem elde edilmiştir. Bu bakımdan literatürdeki diğer çalışmaların bir adım ötesine geçmektedir.

4. Sonuç

Bu çalışmada, hareket eden bir tren üzerindeki pantograf boynuzlarının görüntü işleme ve derin öğrenme modeli ile tespit edilip, ESA mimarisi ile hatalı veya sağlıklı şeklinde sınıflandırma işleminin yapılabilmesi için bir yöntem önerilmiştir. Çalışma, gerçek bir düzenek üzerinde oluşturulmadan önce örnek hataların simülasyon üzerinde modellenmesiyle gerçekleştirilmiştir. Bu bakımdan simülasyon videolarında bulunan sağlıklı ve hasarlı pantograf boynuz örnekleri; eğitim, test ve doğrulama için ayrıştırılmış ve modellerin eğitimi ve testi için kullanılmıştır. Pantograf boynuzundaki hatanın tespitinden önce pantograf boynuz bölgelerinin bulunması oldukça zorlu bir işlemdir. Farklı hava şartlarında, farklı ışık ortamlarında ve farklı arka planlarla

oldukça zorlu görüntüler elde edilmektedir. Bu sebeple pantografin tespiti direkt olarak bir yapay zekâ algoritması ile bulunamamaktadır. Önerilen yöntemde bu problemi aşabilmek için temel görüntü işleme teknikleri uygulanmış ve arka plan ile pantografin bütünü ayrıştırılmıştır. Daha sonra, pantograf bölgesi YOLOv3 derin öğrenme modeli ile tespit edilmiş ve son olarak tasarlanan bir ESA modeli ile pantograf boynuzunun sağlıklı veya hatasız olarak sınıflandırılması sağlanmıştır.

Oluşturduğumuz test veri setindeki 361 sağlıklı pantograf boynuzunun 329 tanesinin sağlıklı, 762 hatalı pantograf boynuzunun 742 tanesinin hatalı olarak sınıflandırılabilirdiği kanıtlanmış ve nicel değerler olarak gösterilmiştir. Bu sonuçlara dayanarak önerilen yöntemin %95'in üzerinde doğruluk ile çalıştığı ispatlanmıştır. Geliştirilen bu yöntem sağladığı yüksek doğruluk derecesi ile literatüre yeni bir yöntem sunmaktadır. Pantograf denetleme sistemi gerçekleştirildiğinde de önerilen yöntemin sadece gerçek veriler üzerinde eğitilip çalıştırılması ile pantograf boynuz kusurlarının tespiti sağlanabilecektir.

Teşekkür

Bu çalışma TCDD tarafından desteklenen Otomatik Tren Muayene İstasyonu Geliştirilmesi Projesi kapsamında TÜBİTAK RUTE Robotik ve Akıllı Sistemler Grubu tarafından yapılmıştır. TCDD ve TÜBİTAK RUTE çalışanlarına çalışmaya katkılarından dolayı teşekkür ederiz.

Kaynakça

- [1] S. Judek and L. Jarzebowicz, "Algorithm for automatic wear estimation of railway contact strips based on 3D scanning results," *2014 International Conference and Exposition on Electrical and Power Engineering (EPE)*, 2014, pp. 724-729, doi: 10.1109/ICEPE.2014.6970004.
- [2] E. Di Stefano, C. A. Avizzano, M. Bergamasco, P. Masini, M. Menci and D. Russo, "Automatic inspection of railway carbon strips based on multi-modal visual information," *2017 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*, 2017, pp. 178-184, doi: 10.1109/AIM.2017.8014015.
- [3] L. Jarzebowicz and S. Judek, "3D machine vision system for inspection of contact strips in railway vehicle current collectors," *2014 International Conference on Applied Electronics*, 2014, pp. 139-144, doi: 10.1109/AE.2014.7011686.
- [4] P. Capece et al., "PANTOBOT-3D: An automatic vision-based inspection system for locomotive pantographs," *7th IET Conference on Railway Condition Monitoring 2016 (RCM 2016)*, 2016, pp. 1-5, doi: 10.1049/cp.2016.1208.
- [5] E. Karaköse, M. T. Gencoglu, M. Karaköse, I. Aydın and E. Akin, "A New Experimental Approach Using Image Processing-Based Tracking for an Efficient Fault Diagnosis in Pantograph-Catenary Systems," in *IEEE Transactions on Industrial Informatics*, vol. 13, no. 2, pp. 635-643, April 2017, doi: 10.1109/TII.2016.2628042.
- [6] D. Li, "A high-efficiency method of pantograph collector strip wearing inspection based on stereo vision," *2019 2nd International Conference on Information Systems and Computer Aided Education (ICISCAE)*, 2019, pp. 389-392, doi: 10.1109/ICISCAE48440.2019.221659.
- [7] X. Yao, Z. Xing, A. Sheng and Y. Chen, "An Image-Based Online Monitoring System for Pantograph Wear and Attitude," in *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-12, 2022, Art no. 5013812, doi: 10.1109/TIM.2022.3178466.
- [8] O. Yaman, M. Karaköse, İ. Aydın and E. Akin, "Detection of pantograph geometric model based on fuzzy logic and image processing," *2014 22nd Signal Processing and Communications Applications Conference (SIU)*, 2014, pp. 686-689, doi: 10.1109/SIU.2014.6830322.
- [9] Karaköse, M. , Yaman, O. , Aydın, İ. & Akin, E. (2017). Pantograf Katener Sistemlerde Görüntü Segmantasyon Tabanlı Adaptif Ark Tespiti . *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* , 10 (2) , 53-63 . Retrieved from <https://dergipark.org.tr/tr/pub/tbbmd/issue/33390/283899>.
- [10] D. Zhang, S. Gao, L. Yu, G. Kang, D. Zhan and X. Wei, "A Robust Pantograph-Catenary Interaction Condition Monitoring Method Based on Deep Convolutional Network," in *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 5, pp. 1920-1929, May 2020, doi: 10.1109/TIM.2019.2920721.

- [11] L. Chang, Z. Liu and Y. Shen, "On-line Detection of Pantograph Offset Based on Deep Learning," 2018 *IEEE 3rd Optoelectronics Global Conference (OGC)*, 2018, pp. 159-164, doi: 10.1109/OGC.2018.8529918.
- [12] Shen, Yuan and Pan, Xiao and Chang, Luonan, "Online Intelligent Perception of Pantograph and Catenary System Status Based on Parameter Adaptation," *Applied Sciences*, 2021, no. 4, doi: 10.3390/app11041948.
- [13] Q. Chen, L. Liu, R. Han, J. Qian and D. Qi, "Image identification method on high-speed railway contact network based on YOLO v3 and SENet," 2019 *Chinese Control Conference (CCC)*, 2019, pp. 8772-8777, doi: 10.23919/ChiCC.2019.8865153.
- [14] Lowe, D.G. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision* **60**, 91–110 (2004). <https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- [15] Ronneberger, O.; Fischer, P. & Brox, T. (2015), 'U-Net: Convolutional Networks for Biomedical Image Segmentation', cite arxiv:1505.04597Comment: conditionally accepted at MICCAI 2015
- [16] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv [cs.LG], 2014.

Özgeçmiş



Mahmut Ömer BAŞTÜRK

1998'de İstanbul'da doğdu. İlk, orta ve lise öğrenimini İstanbul'da tamamladı. 2021 yılında Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Elektronik mühendisliği bölümünden mezun oldu. Yine 2021 yılında Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim dalında yüksek lisans eğitimine başladı. Yüksek lisans eğitiminin yanında TÜBİTAK RUTE Robotik ve Akıllı Sistemler grubunda görüntü işleme ve yapay zekâ alanlarında çalışmalarına devam etmektedir.

E-Posta: mahmut.basturk.d@tubitak.gov.tr.



Veysel YÜKSEL

1995'de İstanbul'da doğdu. İlk, orta ve lise öğrenimini İstanbul'da tamamladı. 2017 yılında İstanbul Arel Üniversitesi Elektrik Elektronik Mühendisliğinden birinci olarak mezun oldu. Ardından, 2018 yılında Budapeşte'de Stipendium Hungaricum burs programı ile Obuda Üniversitesi, Mekatronik Mühendisliği bölümünde tam burslu yüksek lisans hakkı kazandı. Yüksek lisans eğitimini 2020 yılı sonunda tamamlayıp mezun oldu. Şu an TÜBİTAK RUTE Robotik ve Akıllı Sistemler grubunda görüntü işleme, sinyal işleme ve yapay zekâ alanlarında çalışmalarına devam etmektedir.

E-Posta: veysel.yuksel@tubitak.gov.tr.



Yusuf Engin TETİK

1983'te Adıyaman'da doğdu. 2005 yılında Ege Üniversitesi Bilgisayar Mühendisliği bölümünden mezun oldu. 2009 yılında İzmir Yüksek Teknoloji Enstitüsü Elektronik ve Haberleşme Mühendisliği bölümünde yüksek lisansını, 2014'te ise Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünde doktorasını tamamladı. Yazılım geliştirme alanında 15 yılı aşkın iş tecrübesi olmakla birlikte son 6 yıldır TÜBİTAK RUTE Robotik ve Akıllı Sistemler grubunda başuzman araştırmacı olarak görev yapmaktadır.

E-Posta: yusuf.tetik@tubitak.gov.tr

**Mehmet YILMAZ**

1991'de Bursa'da doğdu. İlk, orta ve lise öğrenimini Bursa'da tamamladı. 2013 yılında Yıldız Teknik Üniversitesi, Makine Fakültesi, Mekatronik Mühendisliği bölümünden mezun oldu. 2015 yılında Bursa Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği ABD'den mezun oldu. TÜBİTAK RUTE Robotik ve Akıllı Sistemler grubunda sistem dinamiği, modelleme ve kontrol çalışmalarına devam etmektedir.

E-Posta: mehmet.yilmaz@tubitak.gov.tr

**Mustafa GÜNER**

1990' da İstanbul' da doğdu. İlk, orta ve lise öğrenimini İstanbul' da tamamladı. 2012 yılında Ömer Halisdemir Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. 2019 yılında Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği, Elektronik ABD'den mezun oldu. TÜBİTAK RUTE Robotik ve Akıllı Sistemler grubunda elektronik donanım tasarım alanında yeni nesil sensör geliştirme ve yüksek hızlı karışık sinyal sistemlerin tasarım çalışmalarına devam etmektedir.

E-Posta: mustafa.guner@tubitak.gov.tr

**Tolgahan KAYA**

1985'te Gümüşhane'de doğdu. 2008 yılında Orta Doğu Teknik Üniversitesi Makine Mühendisliği bölümden mezun oldu. 2011 yılında İstanbul Teknik Üniversitesi Makine Mühendisliği Bölümünde yüksek lisansını, 2019 yılında da doktorasını tamamladı. 13 yılı aşkın iş tecrübesi olmakla birlikte, 10 yıldır TÜBİTAK araştırmacı olarak çalışmaktadır ve 2 yıldır Raylı Ulaşım Teknolojileri Enstitüsünün Teknik Müdür Yardımcılığı görevini yürütmektedir.

E-posta: Tolgahan.kaya@tubitak.gov.tr

Beyanlar:

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Yazarların katkıları: Yazar katkıları belirtilmemiştir.