

Mask R-CNN Algoritmasını Kullanarak Demiryolu Travers Eksikliklerinin Tespiti İçin Otonom İHA Tasarımı

Emre GÜÇLÜ¹, İlhan AYDIN^{2*}, Erhan AKIN³

^{1,2,3} Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye
¹ emreguculu1367@gmail.com, ² iaydin@firat.edu.tr, ³ eakin@firat.edu.tr

(Geliş/Received: 22/12/2021;

Kabul/Accepted: 08/02/2022)

Öz: Demiryolları, genellikle aralarında belirli mesafe ile monte edilen traversler aracılığıyla balast altyapısı tarafından desteklenen çelik raylardan oluşur. Traversler ve bağlantı elemanları demiryollarının önemli bileşenleridir. Bu nedenle, bu bileşenlerin eksikliği, önemli sorunlara yol açabilir. Ancak, traverslerin denetlenmesi ve gerçek demiryolu sahasında travers eksikliklerinin tespiti için teknoloji eksikliği vardır. Bu çalışma, demiryollarında bulunan traverslerin kayma ve eksiklik durumlarını incelemek için otonom İHA uçuş kontrol yöntemi önermektedir. Çalışma, otonom ray takibi ve travers kusurlarını inceleme üzere ikiye ayrılmaktadır. İlk bölümde İHA'nın, demiryolunu otonom olarak gezinerek veri toplayabilmesi için ray takip algoritması geliştirilmiştir. İkinci bölümde, Mask R-CNN, travers tanıma ve eksiklik tespiti için eğitilmiştir. Tespit oranını ve verimliliğini artırmak amacıyla travers eksiklik tespiti için Mask R-CNN kullanılmıştır. Travers tespitinden sonra traversler arası mesafeler ölçülerek traverslerdeki eksiklikler tespit edilmiştir. Çalışmanın sınıflandırma başarı oranı %97'dir. Uygulanan yöntem geleneksel yöntemlere kıyasla maliyetleri önemli ölçüde azaltmaktadır. Bu çalışma, travers eksikliklerinin tespiti ile mevcut rayların denetlenmesi için değerli olup, geleneksel yöntemlere kıyasla maliyetleri önemli ölçüde azaltmaktadır.

Anahtar kelimeler: Otonom İHA, Kusur Tespiti, Travers Kusurları

Autonomous UAV Design for Detection of Railway Sleeper Deficiencies Using Mask R-CNN

Abstract: Railroads usually consist of steel rails supported by ballast infrastructure via sleepers mounted at a certain distance between them. Sleepers and fasteners are important components of railways. Therefore, the lack of these components can lead to significant problems. However, there is a lack of technology for inspecting sleepers and detecting sleeper deficiencies at the actual railway site. This study proposes an autonomous UAV flight control method to examine the slip and deficiency conditions of sleepers on railways. The study is divided into two as autonomous track tracking and analysis of sleepers defects. In the first part, a rail tracking algorithm has been developed for the UAV to collect data by navigating the railway autonomously. In the second part, Mask R-CNN is trained for traverse recognition and deficiency detection. Mask R-CNN was used for sleepers missing detection to increase detection rate and efficiency. After the determination of the sleeper, the distances between the sleepers were measured and the deficiencies in the sleepers were determined. The classification success rate of the study was 97%. The applied method significantly reduces costs compared to traditional methods. This work is valuable for detecting sleeper deficiencies and inspecting existing rails, significantly reducing costs compared to traditional methods.

Key words: Autonomous UAV, Defect Detection, Sleepers Defects

1. Giriş

Demiryolu denetimi, güvenli ve hızlı ulaşım için belirli aralıklarla yapılması gereken yüksek maliyetli bir işlemdir. Günümüzde uygulanan, demiryolu denetimlerinin çoğu görsel incelemeye dayanmaktadır. Geleneksel yöntemlerle demiryolu denetiminde, demiryolu hattı boyunca yürüyen ve bileşenlerin durumunu kontrol eden eğitimli personeller görev yapmaktadır. Ancak bu yöntem verimsiz ve maliyetlidir. Ayrıca, bu yöntemler muazzam iş gücü tüketmektedir. Geleneksel yöntemlerle denetim uzun periyotlarda yapılmaktadır. Ancak uzun muayene periyodu, kusurların zamanında tespit edilememesine neden olmaktadır. Otomatik inceleme yöntemlerinin gelişmesiyle, geleneksel yöntemlerin dezavantajlarının üstesinden gelmek için daha gelişmiş kusur tespiti yaklaşımları tasarlanmıştır [1]. Demiryolu denetimi için bilgisayarlı görme tabanlı otomatik denetim sisteminin tasarlanması, hat güvenliğinin sağlanması ve bakım maliyetlerinin düşürülmesi açısından önemlidir. Özellikle son yıllarda denetim güvenliğini artırabilecek ve demiryolu trafiği kesintisini önleyebilecek denetim yöntemleri geliştirilmektedir. Akustik emisyon denetimi [2], elektromanyetik tomografi [3], makine öğrenimi [4], ultrasonik

* Sorumlu yazar: iaydin@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-4566-7517, ² 0000-0001-6880-4935, ³ 0000-0001-6476-9255

algılama [5] gibi çeşitli yöntemler kullanılmaktadır. Son yıllarda, bilgisayarların hesaplama hızlarının artmasıyla beraber demiryolu denetimi için bilgisayarlı görme üzerinde çeşitli araştırmalar yapılmaktadır [6-9].

Demiryolu denetimleri, bağlantı elemanları, ray, balast bölümü, traversler ile ilgili kusurların tespit edilmesine odaklanmaktadır. Demiryolu traversleri, demiryollarında çok sayıda bulunan bileşendir. Bu nedenle demiryolu denetiminin önemli bir parçasıdır. Traversler, bağlantı elemanları ile birlikte rayları belirli bir genişlikte sabitleyen, genellikle betondan oluşan ve trenden gelen yükü altyapıya dağıtan temel bileşendir [10]. Bu nedenle, traversler arasındaki açıklıklar ciddi sorunlara yol açabilir [11]. Ayrıca, eksik traverslerin zamanında tespit edilmesi kritik önem taşımaktadır. Literatür incelendiğinde, traverslerin denetimi için çeşitli çalışmalar yapıldığı görüldü de bu alanda büyük eksiklikler bulunmaktadır [12]. Traverslerin incelenmesi için bilgisayarlı görme tabanlı teknikler önemli bir potansiyele sahiptir.

Bilgisayarlı görme tabanlı travers denetimi için yüksek çözünürlüklü bir kamera ile demiryolu görüntülerinin toplanması gerekmektedir. Bu amaçla, çoğu araştırmada bir denetim treninin altına kamera yerleştirilmesi ile görüntü toplanmaktadır [13-14]. Ancak, tekniğin sınırlı bir alanı algılama aralığı ve yüksek maliyet gibi dezavantajları vardır. Bu dezavantajların üstesinden gelebilmek için İnsansız Hava Aracı (İHA) gibi alternatif araçların kullanılması gerekmektedir. İHA'lar hızları, geliştirilmiş bataryaları ve yüksek tespit verimliliği sayesinde, demiryollarının incelenmesi için güçlü araçlardır. İHA'lar, üzerlerinde bulunan kameralarla demiryolundan görsel veri yakalama özelliğine ek olarak kısa sürede geniş alanı tarama potansiyeline sahiptir. Bu özelliğiyle İHA ile demiryolu denetimi, manuel denetimlere oranla daha kısa denetim süresine sahiptir.

İnsansız Hava Araçları (İHA), üzerinde pilotu olmayan hava araçlarıdır. İHA kullanımındaki artış, sivil, ticari ve askeri alanlarda ivme kazanmıştır. Bunun nedeni, İHA'ların gelişmesi, küresel İHA üretiminin artması ve daha ucuz hale gelmesi ile erişebilir olmasıdır. İHA'lar uygun maliyetleri, iş gücünün azaltılması, çalışanların güvenliğinin sağlanması ve insanların erişemeyeceği yerlere kolayca erişebilmesi nedeniyle birçok alanda kullanılmaktadır. Son yıllarda, çeşitli durumları ve altyapıları izlemek için İHA kullanımına artan bir ilgi vardır. Yangınların izlenmesi [15], fotovoltaiik panellerdeki kusurların incelenmesi [16], arama kurtarma görevleri [17], hedef takibi [18] gibi görevlerde kullanımı oldukça yaygındır. Bunların yanında, İHA'lar demiryollarında bulunan kusurların tespiti için de kullanılabilir [19]. Demiryolu denetiminde karşılaşılan temel sorunlardan biri, denetim sırasında hattın meşgul edilmesidir. İHA'lar, demiryollarını meşgul etmeyerek iş verimliliğini artırma potansiyeline sahiptir. Ayrıca, demiryollarında oluşabilecek kusurlar, İHA inceleme sistemi tarafından görüntülenebilir ve daha fazla analiz edilebilir. Bu nedenle son zamanlarda araştırmacılar, denetimlerde İHA'ları kullanmaya başladılar. [20]'de İHA üzerinde LiDAR yerleştirilerek çerçeve ve diyagramları meşgul etmeden hizmette olan hatlardan verimli bir şekilde veri toplanabilmektedir. Başka bir çalışmada FCN-8 ağı ile İHA tarafından toplanan görüntülerden ray segmentasyonu yapılarak raydaki kusurlar tespit edilmiştir [21]. İnsan gözlemcilerle gerçekleştirilen geleneksel denetimlere kıyasla İHA kullanımının ana avantajı, hattın meşgul edilmemesi ve bunun sonucunda trenlerin optimum kapasitede çalışabilmesidir.

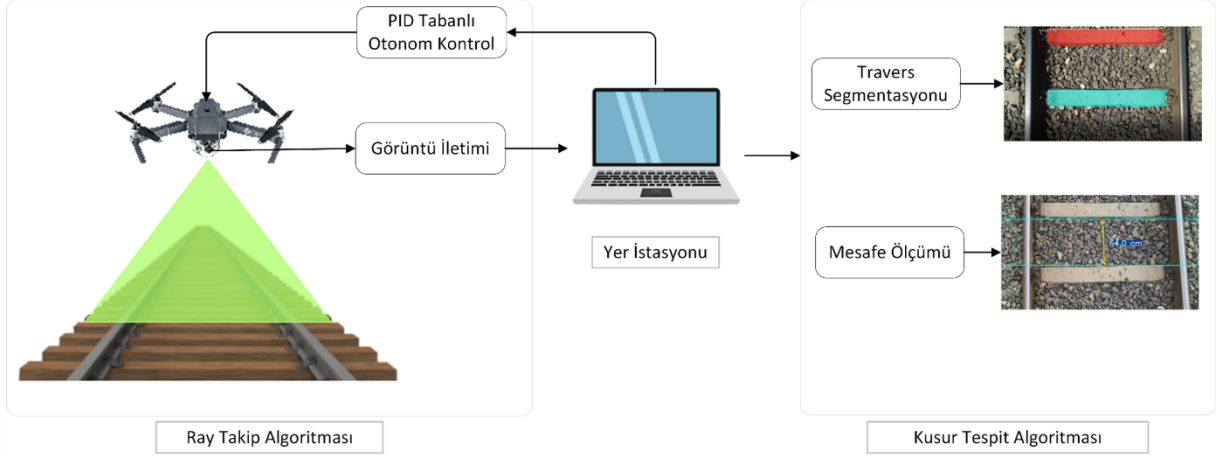
İHA'ların kontrolü için genellikle iki yöntem vardır. Bu yöntemlerden ilki yer istasyonu tarafından komutlarla uzaktan kontroldür. Diğer yöntem ise önceden tanımlanmış algoritmalarla araç bilgisayarı tarafından otonom olarak kontrol edilmesidir [22-26]. Kusur denetimi için otonom İHA'ların kullanımı, insan müdahalesini en aza indirecektir. Bu şekilde, verimlilik ve doğruluk artacaktır.

Bu makalenin kalanı şu şekildedir: Bölüm 2'de travers eksikliklerinin tespiti için önerilen yöntem açıklanmıştır. Bölüm 3'te Ray takip algoritmasının adımları açıklanmıştır. Bölüm 4'te demiryolundan toplanan görüntüler üzerinde travers tespiti ve mesafe ölçümü için yöntemler açıklanmıştır. Bölüm 5'te, tasarlanan otonom İHA algoritmasının demiryolu sahasında test sonuçları verilmiştir. Ardından demiryolundan toplanan görüntüler üzerinde travers eksikliklerinin tespiti için testler yapılarak sonuçlar verilmiştir. Bölüm 6, genel sonuçlar ve değerlendirme içerir.

2. Önerilen Yöntem

Önerilen yöntemin tasarımı Şekil 1'de görselleştirilmiştir. Mimarının temel bileşenleri bilgisayar ve İHA'dır. İHA, bilgisayarın bağlanabileceği bir Wi-Fi ağı sağlamaktadır. İHA kamerasından video verilerini aktarmak için yüksek Wi-Fi bant genişliği gereklidir. İletişim için TCP ve UDP mesajları kullanılır, ancak Parrot SDK bunu yüksek seviyeli komutlara özetler. İHA, bilgisayara video ve durum verilerini gönderir. Bilgisayar bu verileri işler ve uçuş komutlarını geri gönderir. Video akışını işlemek için bilgisayarla görme algoritmaları kullanılır. Daha yüksek bilgi işlem gücünden yararlanmak için görme algoritmalarıyla ilgili hesaplama için güçlü bir bilgisayar kullanmak hızı artıracaktır. Tasarlanan otonom ray takip algoritmasıyla veriler toplandıktan sonra ikinci aşamada, toplanan veriler üzerinde kusur tespit algoritması çalıştırılmıştır. Traversler, Mask R-CNN algoritması ile bölümlendikten sonra aralarındaki mesafe ölçülerek eksiklik ve açıklıklar tespit edilmiştir.

Önerilen yöntem için üzerinde yerleşik bir kamerası olan bir İHA gereklidir. Bilgisayara gerçek zamanlı video akışı sağlaması ve komut alabilmek için SDK'sı olması gerekmektedir. Bu nedenle çalışmada bu ihtiyaçları sağlayan, Parrot Anafi 4K kullanılmıştır. Anafi'nin öne çıkan en önemli özelliği, kamerayı 180 derece hareket ettirebilmesidir. Bu özelliği sayesinde kamera 90 derece raya bakacak şekilde konumlandırılarak tek kamera ile hem ray takibi yapılmış hem de kusur tespiti yapılmıştır.



Şekil 1. Önerilen yöntemin tasarımı

3. Ray Takip Algoritması

Çalışmanın bu bölümü, İHA ile otonom ray takibi için kamera verilerini ve bilgisayar görmesini kullanan bir algoritma geliştirmeyi ele almaktadır. Otonom İHA ile ray takibi algoritması üç ana bölüme ayrılabilir. Bunlar; ray tespiti, İHA'nın bulunması gereken konumu hesaplama ve PID denetleyici kullanarak ray takibidir. Ray çizgilerinin tespiti, otonom sürüş için önemli bir temeldir. Bu nedenle ilk olarak, ray çizgilerini tespit etmek için temel yaklaşım olan HSV renk dönüşümüne ve histogram analizine dayalı bir yaklaşım sunulmuştur. Ardından İHA'nın raya göre konumunu belirleyebilmek için ray çizgilerinin orta noktası hesaplanmıştır. İHA'nın bulunması gereken konum bilgisi, PID denetleyici kullanılarak ray takibinde kullanılmıştır.

3.1 Ray çizgilerinin tespiti için önerilen yaklaşım

Bu çalışmada, belirli bir renge sahip rayları tespit etmek için renk bölütleme kullanılmıştır. İHA kamerasından alınan görüntü RGB renk uzayındadır. Renk modeli dönüşümü, ray tespitinin vazgeçilmez bir parçasıdır. Gerçek demiryolu ortamı farklı bileşenler ve dış ortamdan oluşur. Böyle bir ortamdan alınan RGB görüntülerde renk bilgileri oldukça karmaşıktır. Ray görüntüsünün arka plandan ayrılması zor olmaktadır. RGB renk uzayı ray çizgilerini görüntüden ayırt etmek için yeterli değildir. Bu nedenle, RGB renk uzayı, renk ve yoğunluk bilgilerinin karıştırılması nedeniyle renk tabanlı algılama için tercih edilmemektedir. Bu durumun üstesinden gelmek için, alınan görüntü HSV renk uzayına dönüştürülmüştür. İHA ray boyunca ilerlerken alınan görüntülerde bulunan rayların renk bilgisi önemli ölçüde değişmez. Bu durum, HSV renk uzayında maskeleyme işlemi ile ray çizgilerinin tespit edilebileceğini göstermektedir.

HSV renk uzayı, silindirik biçimde bir yapıdır ve renkleri renk özü, doygunluk ve parlaklık olarak tanımlar. Renk özü, $0^\circ - 360^\circ$ değerleri arasında açısal bir değerdir. Doygunluk ve parlaklık ise 0-100 arasında değerlerden oluşur. HSV renk alanı, renk ve parlaklığı açıkça ayırır. Ayrıca, yalnızca ton bileşeninin kullanılması, algoritmayı aydınlatma varyasyonlarına karşı daha az duyarlı hale getirir. RGB'den HSV'ye dönüştürme işlemi aşağıdaki denklemlerle sağlanır:

$$H = \begin{cases} \frac{(G - B) * 60}{S}, & \text{if } V = G \\ \frac{(G - B) * 60}{S} + 120, & \text{if } V = G \\ \frac{(G - B) * 60}{S} = 120, & \text{if } V = B \end{cases} \quad (1)$$


$$S = \begin{cases} V - \frac{\min(R, G, B)}{V}, & \text{if } V \neq 0 \\ 0, & \text{diğer} \end{cases} \quad (2)$$

$$V = \max(R, G, B) \quad (3)$$

Rayların tespiti için renk özü, doygunluk ve parlaklık için düşük eşik ve yüksek eşik maskesi uygulanmasıdır. Belirlenen değerlere göre ikili görüntüde bu eşikler içindeki rayı içeren pikseller 1'e ayarlanacak ve kalan pikseller sıfır olacaktır. Uygulanan eşikleme değerleri Tablo 1'de verilmiştir. HSV'nin burada en iyi şekilde çalışmasının nedeni, ray renklerinin aynı olmasıdır. Elde edilen sonuçlar Şekil 2'de gösterilmiştir.


Tablo 1. Ray tespiti için eşik değerleri

Kanal	H	S	V
En Küçük	85	0	61
En Büyük	121	255	255



Şekil 2. (a) RGB renk uzayı (b) HSV renk uzayı


Demiryolu görüntüsüne eşikleme işlemi uygulandıktan sonra, Şekil 3.a'da görüldüğü gibi ray çizgilerinin net bir şekilde öne çıktığı ikili bir görüntü elde edilmiştir. Bu işlemden sonra hangi piksellerin raylara ait olduğu, hangilerinin sol çizgiye ve hangilerinin sağ çizgiye ait olduğu belirlenmelidir. Şerit çizgisi piksel algılaması için görüntüde beyaz piksellere sahip alanlarını bulmak üzere bir histogram oluşturulmuştur. Şekil 3.b'de görüldüğü gibi histogram çizildiğinde iki tepe noktası elde edilecektir. Bu tepe noktaları, sol ray çizgisine karşılık gelen bir sol zirve ve sağ şerit çizgisine karşılık gelen bir sağ zirveyi belirtmektedir.



Şekil 3 Ray konumlarının histogram tabanlı tespiti (a) İkili görüntü (b) Histogram pik noktaları

3.2 İHA konumunun belirlenmesi


İHA'nın kamerası 90 derece aşağı bakacak şekilde ayarlanmıştır. Bu durumda ray merkezi, tespit edilen iki ray çizgisinin ortası olacaktır. Histogram pik noktaları grafiğinde oluşan sağ ve sol pik noktalarının x ekseninde oluşturduğu orta nokta bulunarak İHA'nın bulunması gereken konum işaretlenmiştir. Şekil 4'teki görüntü çerçevesinde İHA'nın bulunması gereken konum işaretlenmiştir. Tespit edilen iki ray çizgisinin orta konumu ve kameranın konumu kullanılarak, İHA'nın raylara göre konumu hesaplanmıştır. Bu işlem sonucu, İHA'nın merkezinin rayların ortasından ne kadar uzakta olduğunu hesaplanmıştır. Bu bilgi, PID denetleyici kullanarak rayın takip edilmesinde kullanılmıştır.



Şekil 4. İHA'nın bulunması gereken konum

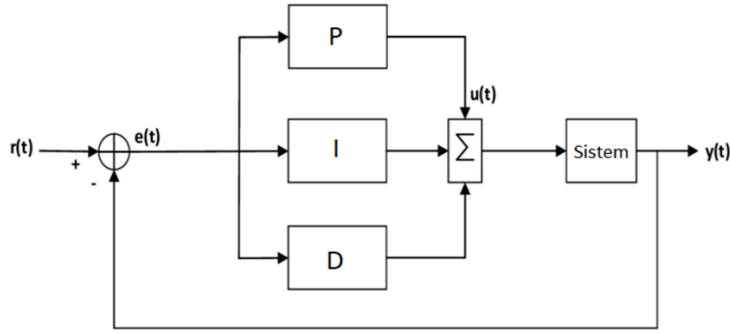
3.3 Ray takibi

Ray takibi, Şekil 5'te gösterilen İHA'nın anlık konumu ile İHA'nın bulunması istenen konum arasındaki mesafenin x ekseninde sıfıra indirgenmesiyle sağlanacaktır. İHA'nın anlık konumu, demiryolundan anlık alınan görüntünün x eksenindeki orta noktasıdır. İstenen konum ise histogram pik noktalarına göre belirlenmiş konumdur. İki nokta arasındaki yatay mesafe sıfırda tutulurken İHA, sabit irtifada ve yükseklikte ilerleyecektir. İki nokta arasındaki mesafe PID denetleyici kullanılarak kapatılacaktır. Bu şekilde demiryolu takibi sağlanmış olacaktır.



Şekil 5. İHA'nın bulunduğu konum ile istenen konumun belirlenmesi

PID denetleyici, sağlamlığı ve yapısı nedeniyle kontrol sistemlerinde kullanılan en yaygın kontrolördür. PID denetleyiciler İHA'ların kontrolünde de yaygın olarak kullanılmaktadır. PID denetleyicinin yapısı sadece üç ayar parametresinden oluşur. Bu nedenle uygulanması kolaydır. PID değerlerinin ayarlanması için çeşitli yöntemler bulunmaktadır. Şekil 6'da görüldüğü üzere klasik PID denetleyici yapısı, sistemden istenen değer ile sistemin o anki gerçek değerinin farkının yani hatanın kendisi, zamana bağlı türevi ve zamana bağlı integralinin toplanarak sisteme gönderildiği geri beslemeli bir denetleyici yapısıdır.



Şekil 6. PID denetleyici yapısı

PID denetleyicinin matematiksel gösterimi aşağıdaki gibidir:

$$U(t) = P_u + I_u + D_u \quad (4)$$

Burada P_u , I_u ve D_u , sırasıyla oransal, integral ve türevsel olarak adlandırılır. K_p oransal katsayı, e hata ve t zaman olmak üzere, oransal terim aşağıdaki gibi ifade edilebilir:

$$P_u = K_p e(t) \quad (5)$$

K_i integral katsayısı, e hata, τ integrasyon değişkeni ve t zaman olmak üzere, integral terimi aşağıdaki gibi ifade edilebilir:

$$I_u = K_i \int_0^t e(\tau) d\tau \quad (6)$$

K_d türevsel katsayısı, e hata ve t zaman olmak üzere, türev terimi aşağıdaki gibi ifade edilebilir:

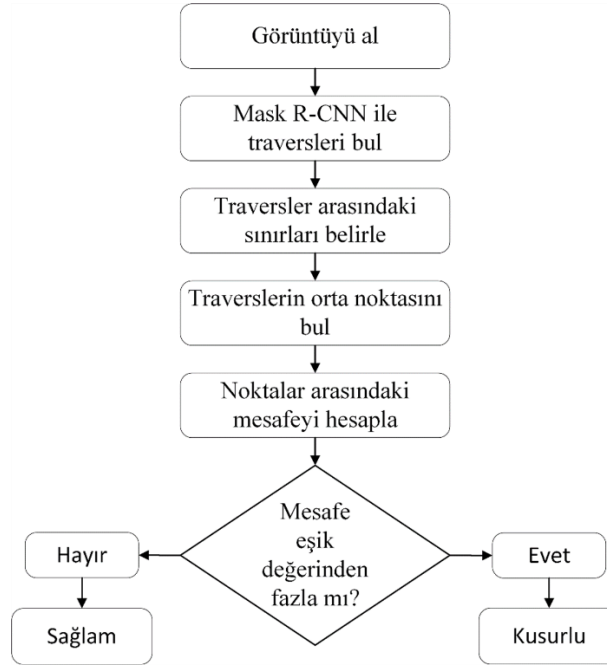
$$D_u = K_d \frac{d}{dt} e(t) \quad (7)$$

PID denetleyicinin çıkışı P,I ve D terimlerinin toplanması ile aşağıdaki gibi elde edilir:

$$U(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + D_u + K_d \frac{d}{dt} e(t) \quad (8)$$

4. Travers Eksikliklerinin Tespiti

Demiryolları, balast yatağına yerleştirilmiş traversler tarafından desteklenen raylarla balastlı raylarda çalışır. Balast üzerine yerleştirilen traversler, demiryolu hattından zemine tren yükünün transferinde önemli bir bileşendir. Bu nedenle, traversler arasındaki açıklıkların fazla olması veya traverslerin eksikliği önemli sorunlara yol açabilir. Bu çalışmada traversler arasındaki açıklıkların tespiti için Mask R-CNN algoritmasına dayalı yöntem kullanılmıştır. Algoritmada ilk olarak Mask R-CNN ile travers tespiti yapılmıştır. Ardından traversler arası ölçüm yapılarak eksik traversler tespit edilmiştir. Travers eksikliklerinin tespiti için önerilen yaklaşımın akış diyagramı Şekil 7’de verilmiştir.




Şekil 7. Travers eksikliklerinin tespiti için önerilen algoritma

4.1 Mask R-CNN

Mask R-CNN, daha hızlı R-CNN (Faster R-CNN) mimarisinden türetilen bir nesne bölütleme algoritmasıdır [27]. Mask R-CNN algoritması, görüntüdeki nesnelere tespit eder ve her nesnenin üzerinde maske oluşturur. Maskeleme tespit edilen nesnenin sınırları içerisinde bulunan piksellerin bölütlenmesi ile gerçekleştirilir.


Mask R-CNN iki aşamalı mimariye sahiptir. İlk aşama bölge teklif ağıdır (RPN). Bu aşamada aday nesnelere aday bölgeler çıkarılır ve hedef sınırlayıcı kutu ile sınıflandırılır. İkinci aşama ise aday olarak belirlenen kutulardan ROI Pooling kullanılarak özelliklerin çıkarılmasıdır. RPN tarafından iki ayrı çıktı oluşturulur. Çıktılardan ilki nesnenin hangi sınıfa ait olduğudur. Diğeri ise nesneyi içine alan sınırlama kutusunun boyutu ve konumudur. RPN tarafından oluşturulan sınırlama kutuları nedeniyle ROI kutuları farklı boyutlarda olabilmektedir. Farklı giriş boyutuna sahip olan görüntüleri işlemek zor olacağından sabit bir giriş boyutu belirlenmelidir. ROI Pooling işlemi burada devreye girmektedir. ROI pooling işlemi sonucunda sınıflandırma ve sınırlama kutusu regresyonu gerçekleştirilir. Sonuç olarak her bölge için maskeleme işlemi gerçekleştirilir. Mask R-CNN algoritmasının mimarisi Şekil 8’deki gibidir.



Şekil 8. Mask R-CNN mimarisi

4.2 Önerilen ölçüm yöntemi

Eğitim için görüntüler demiryolundan Parrot Anafi 4K ile toplanmıştır. Çeşitli açılarda 800 adet görüntü toplanmıştır. Demiryolu görüntüleri 416x219 çözünürlükte JPEG formatına dönüştürülmüştür. Etiketlenen görüntüler 25 adım eğitilmiştir. Uygulama, test için ayrılan rastgele bir görüntü için çalıştırıldığında Şekil 9'da gösterildiği gibi sonuç elde edilmiştir. Burada traversler arası mesafeyi ölçebilmek için üstte kalan traversin alt sınırı ile altta kalan traversin üst sınırı belirlenmiştir. Bu sınırlar Mask R-CNN algoritmasının çizdiği sınırlardan faydalanılarak çizilmiştir. Sınırların belirlenmesi Şekil 9.b'de gösterilmiştir.




Şekil 9. (a) Mask R-CNN algoritmasının çıktısı (b) Ölçüm için sınırların belirlenmesi

Görüntüdeki iki travers arasındaki mesafeyi ölçebilmek için traversler arasındaki mesafe standartlara uyan bir referans görüntü kullanarak bir kalibrasyon yapılmalıdır. Traversler, belirli açıklıklarda dizilirler. Konvansiyonel hatlarda traversler arasındaki mesafesi 63-64 cm olarak uygulanmaktadır. Bu nedenle, referans olarak alınan görüntüdeki mesafe 64 cm olarak belirlenmiştir. Referans görüntüden Denklem 13'teki oran elde edilmiştir.

$$\text{Oran} = \frac{\text{düşey_piksel_sayısı}}{\text{bilinen_genişlik}} \quad (13)$$

Burada bilinen genişlik 64 cm'dir. Aradaki piksel ise Şekil 9.b'de çizilen sınırların arasında dikeyde bulunan piksel sayısıdır. Oran değeri sadece bir kez hesaplanır ve diğer test görüntülerine bu oran uygulanarak ölçüm yapılır. Ölçüm için üst ve alt sınırlarda birer nokta belirlenmelidir. Noktalar, Şekil 9.a'daki sınırların tam orta noktası olarak belirlenmiştir. Belirlenen noktalar kırmızı daire ile işaretlenmiştir. Bu noktalar arasındaki mesafenin ölçümü Şekil 10'da gösterildiği gibi ölçülmüştür.



Şekil 10. Referans görüntüde iki nokta arası ölçüm sonucu


5. Bulgular

Uygulanan ray takip algoritması sahada test edilmiştir. Önerilen ray takip algoritması demir yolunu başarılı bir şekilde takip edebilmektedir. Ray takip algoritmasının karmaşık çalışma koşullarında ve dinamik ortamlarda tanıma performansını doğrulamak için bu çalışmada, İHA ile önceden manuel olarak toplanmış demiryolu görüntüleri kullanılmıştır. Deneyde bu tür videolar İHA kullanılarak toplanmış ve farklı ray koşulları için şerit çizgileri tespit edilmiştir.

Ray takip algoritmasının performansını doğrulamak için gerçek demiryolu sahası deneyleri gerçekleştirilmiştir. Şekil 11’de görüldüğü üzere algoritmanın gerçek zamanlı olarak test edilebilmesi için gerçek demiryolu sahasında testler yapılmıştır. Uygulamada PID denetleyici için K_p , K_i ve K_d değerleri sırasıyla 0.09, 0.05, 3 olarak seçilmiştir. Şekil 12.a, sahada PID denetleyici ile kontrol edilen İHA’nın tepkisini göstermektedir. Şekil 12. b ise PID çıktısının İHA’ya gönderilen dönme değerlerini göstermektedir.




(a)



(b)

Şekil 11. Ray takibi algoritmasının sahada test edilmesi (b) İHA’nın istenen değeri yakalaması



Şekil 12. (a) Demiryolu sahasında ray hattını takip eden İHA'nın orta noktayı yakalaması (b) İHA'ya gönderilen dönme değerleri

Travers eksikliklerinin tespiti için önerilen algoritma 700 sağlam 50 kusurlu demiryolu görüntüsü üzerinde test edilmiştir. Karmaşıklık matrisi; doğruluk, duyarlılık, özgünlük ve F1 değerlerini ölçmek için son derece kullanışlıdır. Bu değerleri hesaplamak için gerekli denklemler aşağıda sırasıyla verilmiştir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YN + YP + DN} \quad (9)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (10)$$


$$\text{Özgünlük} = \frac{DP}{DP + YP} \quad (11)$$

$$F1 = \frac{2 * DP}{2 * DP + YP + YN} \quad (12)$$

Test verilerinin sınıflandırılmasındaki doğruluk oranları 80 cm, 75 cm ve 70 cm eşik değeri için sırasıyla %97,8, %97,7 ve %97,0 olarak bulunmuştur. Algoritma sonucunun diğer metriklerine ait sonuçlar Tablo 2'de verilmiştir. Elde edilen karmaşıklık matrisleri ise Şekil 13'te verilmiştir.

Tablo 2. Diğer ölçütler için performans sonuçları

Eşik değeri	Doğruluk	Duyarlılık	Özgünlük	F1
80 cm	%97,8	%100	%97,7	%98,8
75 cm	%97,7	%100	%97,5	%98,7
70 cm	%97,0	%100	%96,8	%98,4



Şekil 13. Test verilerinin sınıflandırılmasından elde edilen karmaşıklık matrisi (a) Eşik değeri 70 cm için sonuç (b) Eşik değeri 75 cm için sonuç (c) Eşik değeri 80 cm için sonuç

6. Sonuçlar

Bu çalışmanın ilk aşamasında, düşük hesaplama yüküne sahip gerçek zamanlı ray takibi yapabilen otonom İHA kontrol algoritması sunulmuştur. Önerilen yöntem herhangi bir eğitim işlemi gerektirmeden kameradan gelen verileri gerçek zamanlı işleyerek çalışmaktadır. Önerilen algoritma düz rayların yanı sıra kavisli raylarda da raydan çıkmadan iyi bir şekilde ray takibi yapabilmektedir. Çalışmanın ikinci aşamasında ise otonom İHA tarafından toplanan görüntüler üzerinde travers eksikliklerinin tespiti yapılmıştır. Tespit için önerilen algoritma farklı eşik değerleri için %97 üzeri doğruluk oranıyla otomatik demiryolu denetimi için umut vadetmektedir. Gelecekteki çalışmalarımızda, geliştirilen otonom İHA'yı farklı bileşenlerdeki kusurların tespiti için genişletmeyi umuyoruz.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TUBITAK) tarafından 120E097 numaralı proje ile desteklenmiştir.

Kaynaklar

- [1] Edwards, J. R., Hart, J. M., Sawadisavi, S., Resendiz, E., Barkan, C., & Ahuja, N. (2009). Advancements in railroad track inspection using machine-vision technology. In AREMA Conference Proceedings on American Railway and Maintenance of Way Association (Vol. 290).
- [2] Zhang, X., Feng, N., Wang, Y., & Shen, Y. (2014). An analysis of the simulated acoustic emission sources with different propagation distances, types and depths for rail defect detection. *Applied Acoustics*, 86, 80-88.
- [3] Liu, Z., Li, W., Xue, F., Xiafang, J., Bu, B., & Yi, Z. (2015). Electromagnetic tomography rail defect inspection. *IEEE Transactions on Magnetics*, 51(10), 1-7.
- [4] 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.
- [5] Jiang, Y., Wang, H., Tian, G., Chen, S., Zhao, J., Liu, Q., & Hu, P. (2018, July). Non-contact ultrasonic detection of rail surface defects in different depths. In 2018 IEEE Far East NDT New Technology & Application Forum (FENDT) (pp. 46-49). IEEE.
- [6] Du, X., Cheng, Y., & Gu, Z. (2020). Change Detection: The Framework of Visual Inspection System for Railway Plug Defects. *IEEE Access*, 8, 152161-152172.
- [7] Han, Y., Liu, Z., Lyu, Y., Liu, K., Li, C., & Zhang, W. (2020). Deep learning-based visual ensemble method for high-speed railway catenary clevis fracture detection. *Neurocomputing*, 396, 556-568.
- [8] Lu, J., Liang, B., Lei, Q., Li, X., Liu, J., Liu, J., ... & Wang, W. (2020). SCueU-net: Efficient damage detection method for railway rail. *IEEE Access*, 8, 125109-125120.
- [9] Aydin, I., Akin, E., & Karakose, M. (2021). Defect classification based on deep features for railway tracks in sustainable transportation. *Applied Soft Computing*, 111, 107706.
- [10] Li, X., Doh, S. I., Jing, G., Chong, B. W., Suil, A. L., & Chin, S. C. (2021). A comparative review on American, European and Chinese standard for railway concrete sleeper. *Physics and Chemistry of the Earth, Parts A/B/C*, 103073.
- [11] Ortega, R. S., Pombo, J., Ricci, S., & Miranda, M. (2021). The importance of sleepers spacing in railways. *Construction and Building Materials*, 300, 124326.
- [12] Franca, A. S., & Vassallo, R. F. (2020). A method of classifying railway sleepers and surface defects in real environment. *IEEE Sensors Journal*, 21(10), 11301-11309.
- [13] 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.
- [14] Li, Q., & Ren, S. (2012). A real-time visual inspection system for discrete surface defects of rail heads. *IEEE Transactions on Instrumentation and Measurement*, 61(8), 2189-2199.
- [15] Sherstjuk, V., Zharikova, M., & Sokol, I. (2018, April). Forest fire-fighting monitoring system based on UAV team and remote sensing. In 2018 IEEE 38th International Conference on Electronics and Nanotechnology (ELNANO) (pp. 663-668). IEEE.
- [16] Hwang, Y. S., Schlüter, S., Park, S. I., & Um, J. S. (2021). Comparative evaluation of mapping accuracy between UAV video versus photo mosaic for the scattered urban photovoltaic panel. *Remote Sensing*, 13(14), 2745.
- [17] Alotaibi, E. T., Alqefari, S. S., & Koubaa, A. (2019). Lsar: Multi-uav collaboration for search and rescue missions. *IEEE Access*, 7, 55817-55832.
- [18] Rafi, F., Khan, S., Shafiq, K., & Shah, M. (2006, May). Autonomous target following by unmanned aerial vehicles. In *Unmanned Systems Technology VIII* (Vol. 6230, p. 623010). International Society for Optics and Photonics.
- [19] Ghassoun, Y., Gerke, M., Khedar, Y., Backhaus, J., Bobbe, M., Meissner, H., ... & Heyen, R. (2021). Implementation and Validation of a High Accuracy UAV-Photogrammetry Based Rail Track Inspection System. *Remote Sensing*, 13(3), 384.
- [20] Geng, Y., Pan, F., Jia, L., Wang, Z., Qin, Y., Tong, L., & Li, S. (2021). UAV-LiDAR-Based Measuring Framework for Height and Stagger of High-Speed Railway Contact Wire. *IEEE Transactions on Intelligent Transportation Systems*.
- [21] Bojarczak, P., & Lesiak, P. (2021). UAVs in rail damage image diagnostics supported by deep-learning networks. *Open Engineering*, 11(1), 339-348.
- [22] Lygouras, E., Santavas, N., Taitzoglou, A., Tarchanidis, K., Mitropoulos, A., & Gasteratos, A. (2019). Unsupervised human detection with an embedded vision system on a fully autonomous UAV for search and rescue operations. *Sensors*, 19(16), 3542.
- [23] Shiri, H., Park, J., & Bennis, M. (2019, December). Massive autonomous UAV path planning: A neural network based mean-field game theoretic approach. In 2019 IEEE Global Communications Conference (GLOBECOM) (pp. 1-6). IEEE.
- [24] Khadka, A., Fick, B., Afshar, A., Tavakoli, M., & Baqersad, J. (2020). Non-contact vibration monitoring of rotating wind turbines using a semi-autonomous UAV. *Mechanical Systems and Signal Processing*, 138, 106446.
- [25] Wang, C., Wang, J., Wang, J., & Zhang, X. (2020). Deep-Reinforcement-Learning-Based Autonomous UAV Navigation With Sparse Rewards. *IEEE Internet of Things Journal*, 7(7), 6180-6190.
- [26] Güçlü, E., Aydın, İ., & Akın, E. (2021, July). Fuzzy PID Based Autonomous UAV Design for Railway Tracking. In 2021 International Conference on Information Technology (ICIT) (pp. 456-461). IEEE.
- [27] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).