



İHA tabanlı fotogrametrik veriler ile derin öğrenme destekli yol çatlaklarının otomatik tespiti

Deep learning-assisted automatic road crack detection from UAV-based photogrammetric data

Mustafa Emre Döş^{1*} , Abdurahman Yasin Yiğit² , Murat Uysal³

¹Mimarlık ve Şehir Planlama Bölümü, Antakya Meslek Yüksekokulu, Hatay Mustafa Kemal Üniversitesi, Hatay, Türkiye.

mustafaemre.dos@mku.edu.tr

²Harita Mühendisliği Bölümü, Mühendislik Fakültesi, Mersin Üniversitesi, Mersin, Türkiye.

ayasinyigit@mersin.edu.tr

³Harita Mühendisliği Bölümü, Mühendislik Fakültesi, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye.

muysal@aku.edu.tr

Geliş Tarihi/Received: 23.07.2025

Düzeltilme Tarihi/Revision: 15.09.2025

doi: 10.65206/pajes.93043

Kabul Tarihi/Accepted: 15.10.2025

Araştırma Makalesi/Research Article

Öz

Yol üstyapısının en üst tabakasında meydana gelen yüzey çatlakları, zamanında müdahale edilmediğinde yapısal bozulmalara ve bakım maliyetlerinin artmasına neden olmaktadır. Özellikle köprü yüzeyleri gibi kritik bileşenlerde çatlakların erken tespiti, yapısal bütünlüğün korunması açısından büyük önem taşımaktadır. Geleneksel denetim yöntemleri ise zaman alıcı, maliyetli ve genellikle öznel değerlendirmelere dayalıdır. Bu çalışma, çatlak tespiti sürecinde hem görsel hem de konumsal doğruluk sağlayan yeni nesil bir yaklaşım sunmak üzere, İnsansız Hava Aracı (İHA) görüntülemesi, fotogrametrik modelleme ve derin öğrenme tekniklerini entegre eden bütüncül bir yöntem önermektedir. Kırsal bir yol kesiminde toplanan yüksek çözünürlüklü görüntüler fotogrametri iş akışı ile değerlendirilmiştir. Yapılan doğruluk analizinde iç yöneltilme (kamera kalibrasyonu) hatası, dengeleme sonrasında 1.83 mm olarak belirlenmiştir. Dış doğruluk (üç boyutlu (3B) konumsal hassasiyet) ise 2.14 mm Kök Ortalama Kare Hata (Root Mean Square Error - RMSE) değeriyle doğrulanmıştır. Elde edilen ortomozaik görüntüler üzerinde, Transformatör tabanlı CT-CrackSeg kullanılarak otomatik çatlak tespiti gerçekleştirildi. Çatlak maskeleri, saha gözlemleri ve referans ölçümlerle karşılaştırılmış; %92.5 Kesinlik (Precision), %88.3 Duyarlılık (Recall), %90.3 F1-Skoru ve %87.6 Birleşim Üzerinden Kesişim (Intersection over Union-IoU) metrik değerleri elde edilmiştir. Çalışma sonuçları, önerilen yöntemin özellikle düşük trafikli ve yapısal riski yüksek yüzeylerde hızlı, hassas ve tekrar üretilebilir çatlak tespiti için etkin bir çözüm sunduğunu göstermektedir. Yüksek çözünürlüklü, koordinatlı görüntülerin derin öğrenme ile bütünlük kullanımı, çatlakların hem morfolojik hem de mekânsal analizi açısından literatürde öne çıkan güçlü bir uygulama senaryosu ortaya koymaktadır. Bu yaklaşım, yol bakım yönetim sistemlerine entegre edilerek, proaktif ve veri temelli karar destek mekanizmalarının gelişimine katkı sağlayabilecek niteliktedir.

Anahtar kelimeler: Derin öğrenme, Doğruluk analizi, İHA Fotogrametrisi, Segmentasyon, SfM, Yol çatlak tespiti.

Abstract

Surface cracks in pavement structure, if not addressed in a timely manner, can lead to structural deterioration and increased maintenance costs. Early detection of cracks, particularly on critical components such as bridge surfaces, is essential for preserving structural integrity. However, traditional inspection methods are time-consuming, costly, and often rely on subjective assessments. This study proposes an integrated, next-generation approach for crack detection that combines Unmanned Aerial Vehicle (UAV) imaging, photogrammetric modeling, and deep learning techniques to ensure both visual and positional accuracy. High-resolution images collected along a rural road section were evaluated using a photogrammetry workflow. In the accuracy analysis performed, the internal orientation (camera calibration) error was determined to be 1.83 mm after balancing. External accuracy (three-dimensional (3D) positional accuracy) was verified with a Root Mean Square Error (RMSE) value of 2.14 mm. On the resulting orthomosaic images, automatic crack detection was performed using Transformer-based CT-CrackSeg. The predicted crack masks were validated against field observations and reference measurements, yielding 92.5% Precision, 88.3% Recall, 90.3% F1-Score, and 87.6% Intersection over Union (IoU). The results demonstrate that the proposed method provides a reliable, repeatable, and practical solution for fast and accurate crack detection, particularly in low-traffic and structurally sensitive environments. The integration of high-resolution, georeferenced imagery with deep learning enables both morphological and spatial analysis of cracks, offering a powerful use case in current literature. This approach is well-suited for integration into road maintenance management systems and can support the development of proactive, data-driven decision support mechanisms.

Keywords: Deep learning, Accuracy analysis, UAV photogrammetry, Segmentation, SfM, Crack detection.

1 Giriş

Karayolları, ekonomik kalkınmanın, sosyal yaşamın ve kentsel gelişimin temel unsurlarından biri olarak stratejik önem taşımaktadır [1]. Artan nüfus, yoğun araç trafiği ve değişken iklim koşulları gibi etkenler, yol üstyapısının hızlı bir şekilde yıpranmasına ve deformasyonların sık görülmesine neden

olmaktadır [2]. Bu durum, sürüş güvenliğini doğrudan etkilemekte ve ulaşım kalitesini düşürmektedir [3]. Yollarda en sık karşılaşılan bozulma türlerinden biri olan yüzey çatlakları, zamanında müdahale edilmediğinde [4],[5] daha geniş yüzey bozulmalarına ve dolayısıyla daha yüksek bakım maliyetlerine yol açmaktadır. Yol bozulmaları genellikle üstyapının en üst tabakasında ortaya çıkmaktadır. Bu tabaka, uygulama yöntemine bağlı olarak sıcak karışım asfalt (aşınma tabakası),

*Yazışılan yazar/Corresponding author

taş mastik asfalt, binder veya sathi kaplama şeklinde olabilmektedir. Çalışmada ele alınan çatlak türü bozulmalar da bu tabakalarda gözlemlenmekte olup, yolun servis ömrünü kısaltan en yaygın deformasyonlardan birini oluşturmaktadır. Yol yüzeylerinde oluşan çatlaklar, genellikle şekil ve oluşum nedenlerine göre sınıflandırılmaktadır. En yaygın çatlak tipleri arasında boyuna çatlaklar (trafik yönüne paralel), enine çatlaklar (trafik yönüne dik), timsah sırtı çatlakları (çok yönlü küçük çatlak ağları), yansıma çatlaklar (altyapıdaki derzlerin yüzeye yansıması) ve kenar çatlakları (yol kenarlarında oluşan çatlaklar) yer almaktadır [6]. Her çatlak türü, farklı bakım stratejileri ve yapısal müdahale gerektirdiğinden, bu tiplerin otomatik olarak ayırt edilmesi yol bakım sistemleri açısından büyük önem taşımaktadır. Bu nedenle, yolların düzenli olarak denetlenmesi, bozulmaların erken tespiti ve önleyici bakım uygulamalarının planlanması, altyapı yönetim süreçlerinin vazgeçilmez bir parçasıdır [7].

Yol denetimi, geçmişten günümüze farklı tekniklerle yürütülmüştür [1]. Geleneksel denetim yöntemleri yüksek maliyetlidir ve ayrıca insan hatasına açıktır [8]. Bu yöntemler her ne kadar detaylı bilgi sağlasa da geniş yol ağlarının sık aralıklarla kontrol edilmesi bakımından oldukça zaman alıcı [7], iş gücü yoğun ve maliyetlidir [9]. Ayrıca, subjektif değerlendirmeler ve insan hatası gibi faktörler, veri tutarlılığını olumsuz etkileyebilmektedir [8]. Bu zorlukların aşılması ve denetim süreçlerinin daha hızlı, nesnel ve geniş alanlara yaygın şekilde uygulanabilir hale gelmesi amacıyla, gelişmiş sensör teknolojileri ve uzaktan algılama tabanlı yöntemler devreye girmiştir [8],[10]. Gelişen uzaktan algılama teknolojileri, bu noktada yol denetimi uygulamalarına yeni bir boyut kazandırmıştır. Özellikle İnsansız Hava Araçları (İHA), yüksek çözünürlüklü görüntüleme kapasitesi, esnek uçuş planlaması ve kısa sürede geniş alanları kapsayabilme yeteneği ile dikkat çekmektedir [4]. İHA'lar, geleneksel yöntemlere kıyasla daha düşük maliyetle daha sık aralıklarla veri toplanmasına olanak tanıyarak bakım planlamasında proaktif bir yaklaşımın benimsenmesine katkıda bulunmaktadır [11]. Ancak, İHA verilerinin etkili bir şekilde kullanılabilmesi, büyük hacimli görüntülerin hızlı ve doğru analiz edilebilmesini gerektirmektedir [12].

Literatürde, İHA görüntülerinden doğrudan iki boyutlu (2B) görüntü işleme veya makine öğrenmesi teknikleriyle çatlak tespiti yapılabildiği örnekler mevcuttur. Ancak bu tür yaklaşımlar genellikle sadece görsel çıktı üretmekte; elde edilen sonuçlar çoğu zaman mekânsal doğruluk taşımadığından, yol bakım yönetim sistemlerine entegre edilebilecek ölçülebilir ve koordinatlı veriye dönüştürülememektedir. İHA ile elde edilen görüntüler, ham haliyle kullanıldığında sadece görsel bilgi sunmakta; mekânsal doğruluk ve koordinat bilgisi açısından sınırlı kalmaktadır [13],[14]. Dolayısıyla bu görüntülerden elde edilecek çatlak bilgisi eklenmiş haritalar, konumsal tabanlı yol bakım kararları için doğrudan yeterli değildir. Ayrıca tespit sonuçlarının hassas konum bilgilerinin de elde edilmesi, bakım planlarının coğrafi bilgi sistemleri (CBS) ve yol yönetim veri tabanları ile entegre edilebilmesi açısından büyük önem taşımaktadır. Bu ihtiyacı karşılamak amacıyla fotogrametrik iş akışları, özellikle Hareket Tabanlı Yapısal Algılama (Structure from Motion/SfM) yaklaşımı, İHA görüntülerinden koordinatlı ortomozaik haritalar ve sayısal yüzey modelleri üretilmesine imkân tanıyarak [14] yol yüzeyinin üç boyutlu (3B) geometrisi ile çatlakların hem görsel hem de konumsal doğruluğunu artırmaktadır [13].

Fotogrametri tabanlı bu iş akışı sayesinde, İHA ile toplanan görüntülerden üretilen ortomozaik harita üzerinde derin öğrenme tabanlı segmentasyon uygulanarak çatlak bölgeleri piksel düzeyinde tanımlanabilmekte, tespit edilen çatlaklar vektör veri formatında çıkarılarak yol yüzeyi üzerinde doğru konumda referanslayabilmektedir [15]. Böylece, sahadan elde edilen verilerin CBS tabanlı altyapı yönetim sistemleriyle doğrudan entegre edilmesi ve zamana bağlı olarak değişim analizlerinin yürütülmesi mümkün hale gelmektedir. Fotogrametri yöntemi ile koordinatlandırılan bu veriler, çatlak tespitinde kullanılacak ileri analiz tekniklerinin etkinliğini de doğrudan etkilemektedir [14],[15]. Yol çatlaklarının İHA görüntülerinden otomatik olarak tespiti için görüntü işleme teknikleri uzun süredir kullanılmaktadır. Kenar algılama, morfolojik işlemler, eşikleme gibi klasik yaklaşımlar, belirli senaryolarda etkin sonuçlar vermekte ancak farklı yol yüzey dokuları, ışık değişimleri, gölge etkileri gibi değişken koşullar altında yeterli doğruluğu her zaman sağlayamamaktadır. Bu nedenle, geleneksel çatlak tespit yöntemlerinin kısıtlamalarının üstesinden gelmek amacıyla, daha verimli ve güvenilir çözümler sunan derin öğrenme tabanlı mimariler geliştirilmiştir [16],[17].

Geçmişte araştırmacılar, çatlakların tespitine yönelik olarak çeşitli klasik makine öğrenmesi yöntemlerinden yararlanmışlardır. Bunlar arasında en sık kullanılanlar arasında Destek Vektör Makineleri (Support Vector Machine-SVM) ile Rastgele Orman (Random Forest-RF) algoritmaları [18] yer almaktadır. Ancak bu yaklaşımlar genellikle manuel özellik seçimine dayandıkları, yüksek düzeyde uzman bilgisi gerektirdikleri ve görüntü çeşitliliği karşısında sınırlı genelleme kabiliyetine sahip oldukları için, istenen doğruluk düzeyine ulaşmakta yetersiz kalmışlardır [17],[19]. Bilgisayarlı görü ve hesaplama gücündeki ilerlemelerin etkisiyle, son yıllarda derin öğrenme mimarileri yol çatlaklarının tespitinde öne çıkmaya başlamıştır [20]-[22]. Derin öğrenme tabanlı çatlak tespit yöntemleri, genel olarak üç temel görev altında sınıflandırılmaktadır: çatlak sınıflandırması, nesne tespiti ve çatlak segmentasyonu. Sınıflandırma ve nesne tespiti yaklaşımları, genellikle yalnızca çatlakların varlığına veya yaklaşık konumuna ilişkin bilgi sağlamakta olup, yapısal bütünlük açısından gereken detay seviyesini sunamamaktadır [18]. Bu tür yöntemler, uygulama kolaylığı ve hızlı tahmin kabiliyeti gibi avantajlar sunsa da çatlakların boyutsal özellikleri ve mekânsal yayılımı hakkında yeterli veri sağlayamaması nedeniyle altyapı planlamasında sınırlı katkı sunmaktadır.

Buna karşın, çatlak segmentasyonu görevleri, görüntü üzerinde piksel düzeyinde işlem yaparak çatlakların konumunu, şekilsel yapısını ve genişlik gibi morfolojik özelliklerini detaylı biçimde tanımlayabilmektedir [23],[24]. Bu sayede, çatlakların mekânsal dağılımı ve geometrisi üzerinde daha hassas analizler yapılması mümkün olmaktadır. Ancak segmentasyon, özellikle yüksek çözünürlüklü görüntülerle çalışıldığında yol yüzeyindeki karmaşık desenler, kirlenmeler, asfalt dokusu ve ince çatlak çizgileri nedeniyle hem teknik olarak daha zorlayıcı hem de hesaplama açısından daha maliyetli bir problem olarak değerlendirilmektedir [25]. Bu bağlamda, son yıllarda geliştirilen ve çatlak segmentasyonu görevinde yaygın olarak kullanılan derin öğrenme mimarilerinden biri olan U-Net, sınırlı etiketli veriye sahip ortamlarda dahi etkili performans göstermesiyle öne çıkmaktadır. U-Net mimarisi, özellikle ince ve düzensiz yapılı çatlakların segmentasyonunda sağladığı hassasiyet ile çatlak analizi için güçlü bir araç olarak değerlendirilmektedir. U-Net'e alternatif olarak geliştirilen

SegNet mimarisi [26], daha kompakt yapısıyla daha düşük hesaplama maliyeti sunmakta ve bu yönüyle hızlı uygulama gerektiren düşük bütçeli projelerde avantaj sağlamaktadır. Bu iki mimari, doğruluk ve işlem süresi arasında denge kurmak isteyen araştırmacılar için uygulama türüne bağlı olarak tercih edilmektedir [27]. Bunun yanında, görüntü segmentasyonu alanında önemli bir yenilik olarak öne çıkan Transformer tabanlı mimariler, çatlak tespitine yönelik uygulamalarda giderek daha fazla kullanılmaya başlamıştır [28]. Bu mimariler, özellikle uzun menzilli bağlamsal bağıntıları öğrenme kapasitesi sayesinde, karmaşık yüzey desenlerinde bile yüksek başarıyla segmentasyon gerçekleştirebilmektedir. Örnek olarak Swin Transformer [29], CrackFormer [30] ve SegFormer [31] gibi yapılar, asfalt yüzeyler üzerindeki bağlam farklarını ve çatlak örüntülerini daha doğru biçimde ayrıştırarak, detaylı mekânsal analizlerde öne çıkmaktadır [25]. Her ne kadar bu yapılar daha yüksek hesaplama gücü gerektirse de sundukları yüksek doğruluk seviyesi, esneklik ve öğrenme kabiliyeti sayesinde gelecekte akıllı altyapı izleme ve yönetim sistemlerinde önemli roller üstlenmeleri beklenmektedir. Bu çalışmada da tercih edilen CT-CrackSeg ise geleneksel U-Net yapısını temel almakla birlikte, çok katmanlı özellik çıkarımı, dikkat (attention) tabanlı modüller ve sınır hassasiyetine sahip segmentasyon birimleri sayesinde çatlak dışı yüzeyleri bastırma, görsel karmaşayı azaltma ve çatlak sınırlarını daha keskin biçimde tanımlama yeteneği sunmaktadır [32]. Ayrıca, sınırlı etiketli veriyle çalışabilme ve düşük parametre sayısıyla yüksek doğruluk elde etme avantajları sayesinde, küçük nesne segmentasyonu gerektiren yol çatlak tespiti uygulamaları için ideal bir çözüm haline gelmiştir.

Bu çalışmada, yol üst yapısının denetlenmesine yönelik modern ve bütüncül bir yaklaşım ortaya koymak amacıyla, İHA görüntülerinden elde edilen koordinatlı ortomozaik veriler üzerine derin öğrenme tabanlı segmentasyon uygulanmıştır. Bu kapsamda, özellikle yol yüzeyindeki ince ve düzensiz çatlakların hassas biçimde tespit edilmesini hedefleyen açık kaynaklı CT-CrackSeg mimarisi tercih edilmiştir. Önerilen yöntemde, SfM fotogrametri yaklaşımıyla elde edilen yüksek çözünürlüklü koordinatlı ortomozaik görüntüler üzerinde CT-CrackSeg mimarisi uygulanarak çatlak bölgeleri piksel düzeyinde ayrıştırılmış, elde edilen maskeler vektör veri formatına dönüştürülerek yol yüzeyi üzerinde doğru şekilde konumlandırılmıştır. Segmentasyon sonuçları, saha gözlemleri ve referans ölçümlerle karşılaştırılarak doğruluk analizleri gerçekleştirilmiştir. Bu yöntem, yalnızca görsel değil aynı zamanda mekânsal doğruluğu da garanti altına alarak çatlakların hem morfolojik hem de konumsal olarak değerlendirilmesine olanak tanımıştır. Geniş ölçekli yol ağlarında uygulanabilirliği test edilen bu yaklaşım, veri temelli, tekrarlanabilir ve sürdürülebilir bir altyapı denetim sisteminin temel bileşeni olarak öne çıkmaktadır.

2 Materyal ve metot

2.1 Çalışma alanı ve veri toplama

Bu çalışma, örnek olay alanı olarak bir köprü üzerindeki yol kesiminde gerçekleştirilmiştir. Çalışma alanındaki yol kesimi, sıcak karışım asfalt kaplama ile inşa edilmiştir. Bu kaplama türü, çatlak türü bozulmaların en sık gözlemlendiği yüzeylerden biri olması nedeniyle çalışmada tercih edilmiştir. Bu çalışma sahasının seçilme nedeni, köprü yüzeyinde oluşabilecek çatlakların zamanla altyapıya sızan su nedeniyle taşıyıcı elemanlarda korozyon ve yapısal zayıflama riskini artırmasıdır. Bu tür bozulmaların erken aşamada tespit edilmesi, köprü

bakım maliyetlerinin azaltılması ve güvenli geçişin sürdürülebilirliği açısından kritik önem taşımaktadır. İncelenen köprü, kırsal bir köy yolu üzerinde yer almakta olup yaklaşık 100 m uzunluğa ve ortalama 10 m genişliğe sahiptir. Düşük trafik yoğunluğu ve bölgenin iklim koşullarına bağlı olarak, yüzeydeki çatlak oluşumlarının daha çok doğal etkenlerden (sıcaklık farkları, donma-çözülme, yağış ve yüzey drenaj eksiklikleri) kaynaklandığı düşünülmektedir.

Veri toplama işlemleri için Parrot Anafi marka İHA kullanılmıştır. İHA üzerinde bütünleşmiş RGB kamera yer almakta olup, sabit odaklı lens yapısı ve 4K görüntüleme kapasitesi ile köprü yüzey detaylarının yüksek çözünürlükte kaydedilmesine olanak tanımaktadır. Uçuş planlaması, köprü yol kesimini tam olarak kapsayacak şekilde yapılmış; ayrıca köprü'nün çevresinde kalan dar bir tampon bölge de uçuş alanına dâhil edilerek YKN görüş alanına girmesi sağlanmıştır. Uçuşlar tam otomatik uçuş modunda ve double grid (çift izgara) uçuş düzeniyle gerçekleştirilmiştir. Bu düzen, her yönde yeterli örtüşme sağlanarak köprü yüzeyinde homojen görüntü dağılımı elde edilmesine imkân tanımıştır. Uçuşlar, köprü yüzeyindeki detayları optimum çözünürlükte kaydedebilmek amacıyla 20 metre yerden yükseklikte icra edilmiştir. Boyuna örtüşme oranı yaklaşık %80, enine örtüşme oranı ise %60 olarak belirlenmiştir. Uçuş hızı, sensörün enstantane süresine uygun olacak şekilde otomatik ayarlanmış ve genellikle 3-4 m/s aralığında tutulmuştur. Veri toplama sırasında hava durumu, görüntü kalitesini olumsuz etkilemeyecek düzeyde açık ve rüzgârsız seçilmiş; görüş mesafesi ve aydınlatma koşullarının uygunluğuna dikkat edilmiştir.

Fotogrametrik işlemde geometrik doğruluk sağlamak amacıyla toplam 16 adet YKN kullanılmıştır. Bu noktaların 10 adedi köprü yüzeyi üzerine, 6 adedi ise köprü çevresindeki zemin üzerine yerleştirilmiştir. Tüm YKN'lerin 3B koordinatları Küresel Konumlama Uydu Sistemi Sürekli Çalışan Referans İstasyonu (Global Navigation Satellite System/GNSS-Continuously Operating Reference Station/CORS) ağı kullanılarak iki oturumda statik yöntemle ölçülmüştür. Ayrıca santimetre altı düzeyde konumsal doğruluk elde edilmiştir. Ölçüm sonrası koordinatlar ulusal datum referansına uygun hale getirilerek fotogrametrik iş akışına entegre edilmiştir.

2.2 Verilerin değerlendirilmesi ve hazırlanması

Toplanan yüksek çözünürlüklü İHA görüntülerinin işlenmesi sürecinde, SfM temelli fotogrametrik iş akışı uygulanmış ve bu amaçla Agisoft Metashape Professional yazılımı tercih edilmiştir. Bu yazılımın tercih edilme nedeni, kullanıcı dostu arayüzü, SfM ve Çok Görünümlü Stereo (Multi-View Stereo/MVS) algoritmalarını entegre bir şekilde sunması, YKN entegrasyonunu desteklemesi ve yüksek hassasiyet gerektiren mühendislik projelerinde yaygın biçimde kullanılmasıdır. Ayrıca, Metashape'in gelişmiş kalibrasyon yetenekleri sayesinde kamera lens distorsiyonlarının giderilmesi, modelin geometrik doğruluğunu artırmakta ve elde edilen ortomozaiklerin konumsal hassasiyetini garanti altına almaktadır.

Fotogrametrik iş akışı, veri kalitesini maksimum düzeyde koruyacak ve çıkış ürünlerinin analizde doğrudan kullanılmasına imkân tanıyacak şekilde kurgulanmıştır. İlk aşamada, uçuş sonrası elde edilen tüm ham görüntüler kalite kontrolünden geçirilmiş; bulanıklık, aşırı pozlama, tekrar eden kareler ve örtüşmesi yetersiz görüntüler elenmiştir. Kalan görüntü seti, kamera kalibrasyon parametrelerini içeren orijinal meta (Exchangeable Image File Format/EXIF)

bilgileriyle birlikte yazılıma aktarılmıştır. Görüntüler arasında yeterli sayıda ortak öznitelik (keypoint) bulunabilmesi için Öçekten Bağımsız Öznitelik Dönüşümü (Scale-Invariant Feature Transform/SIFT) tabanlı öznitelik eşleme algoritması kullanılmıştır. SIFT yöntemi, farklı ölçeklerde ve dönüş açılarında özniteliklerin tespitine imkân tanıyarak özellikle detaylı yol yüzeyi gibi homojen olmayan dokularda eşleşme kalitesini artırmaktadır [33].

Kamera hizalama aşamasında, örtüşen görüntüler arasında SIFT ile eşlenen öznitelikler kullanılarak her bir görüntünün konum ve yönelimi iteratif demet dengeleme (bundle adjustment) işlemiyle optimize edilmiştir. Böylece görüntülerin mekânsal konumları, iç yöneltme (kamera kalibrasyonu) ve dış yöneltme (kameranın uzaydaki konumu/yöneltimi) parametreleri elde edilmiştir ve kaba bir nokta bulutu oluşturulmuştur. Bu aşamada modelin georeferanslanması için toplam 16 YKN kullanılmaktadır. Bu noktalardan 8 tanesi Denetleme Noktası (DN) olarak kullanılarak modelin dengeleme ve hizalama aşamasında pozisyonlandırmayı sağlamış, geri kalan 8 tanesi Denetleme Noktası (DN) olarak ayrılarak modelin son geometrik doğruluğunun bağımsız şekilde test edilmesine imkân tanımıştır. Tüm noktaların 3B koordinatları GNSS CORS ağı üzerinden statik ölçüm yöntemiyle iki oturumda elde edilmiş, ulusal datum referans sistemine uygun biçimde düzenlenerek Metashape'e entegre edilmiştir.

Yoğun nokta bulutu üretim aşamasında, hizalanmış kamera parametreleri ve kaba nokta bulutu temel alınarak MVS algoritması uygulanmıştır. MVS, her görüntü çiftinden epipolar geometri ilişkileri üzerinden derinlik bilgisi hesaplayarak yol yüzeyinin 3B detaylarını yüksek nokta yoğunluğuyla yeniden oluşturur [34]. Elde edilen yoğun nokta bulutu, yol yüzeyindeki mikro detayları, çatlak kenarlarını ve küçük düzensizlikleri temsil edebilecek nitelikte hazırlanmıştır. Gürültülü (noise) noktalar, yazılımın yerleşik filtreleme araçları kullanılarak temizlenmiş ve gerektiğinde manuel düzenleme ile nokta bulutundaki sapmalar düzeltilmiştir. Yoğun nokta bulutu referans alınarak Sayısal Yüzey Modeli (SYM) oluşturulmuştur. Bu SYM üzerinden ortorektifikasyon işlemi yürütülerek yüksek geometrik doğrulukta bir ortomozaik üretilmiştir. Ortomozaik, köprü üzerindeki yol yüzeyinin çatlak detaylarını bozulmasız ve gerçeğe uygun bir ölçekte sunacak şekilde düzenlenmiştir.

Önemli bir aşama olarak, çatlak tespitine yönelik derin öğrenme tabanlı segmentasyonun daha verimli yapılabilmesi için, ortomozaik üretiminin yanı sıra orijinal hava fotoğraflarının lens distorsiyonlarından arındırılmış, koordinatlı ve geometrik sapmalardan temizlenmiş versiyonları da dışa aktarılmıştır. Bu işlem sırasında, yazılımda her görüntü sıkıştırılmalı resim dosyası (Joint Photographic Experts Group/JPEG) olarak, distorsiyonsuz ve referans koordinatları korunmuş halde kaydedilmiştir. Böylece, derin öğrenme algoritması ham kareler üzerinde daha yüksek doğrulukla çalışabilmekte ve tespit edilen çatlak maskeleri, sonradan vektör veri formatında ortomozaik ve SYM üzerine tam uyumlu şekilde yerleştirilebilmektedir. Tüm fotogrametrik ürünler —ortomozaik, nokta bulutu, SYM ve distorsiyonsuz fotoğraflar— projenin referans koordinat sistemine uygun şekilde coğrafi koordinatlı olarak dışa aktarılmıştır. Bu bütünlük veri seti, çatlak tespiti, konumsal analiz ve CBS tabanlı yol bakım planlamasına temel oluşturmaktadır.

2.3 Derin öğrenme tabanlı çatlak tespiti

Derin öğrenme, çok katmanlı yapay sinir ağları kullanarak verilerden anlamlı özniteliklerin otomatik olarak çıkarılmasını sağlayan bir makine öğrenmesi alt dalıdır (Şekil 1).




Şekil 1. Yapay zekâ, makine öğrenmesi ve derin öğrenme hiyerarşisi.

Figure 1. Hierarchy of artificial intelligence, machine learning, and deep learning.

Bu yöntem, geleneksel makine öğrenmesi algoritmalarının gerektirdiği manuel özellik çıkarımı ihtiyacını ortadan kaldırarak, özellikle yapılandırılmamış ve karmaşık veri türlerinde yüksek doğrulukla tahminler yapabilme yeteneğiyle öne çıkmaktadır [35]. Derin öğrenme mimarileri, görüntü işleme görevlerinde gösterdikleri başarı ile yol yüzeyi görüntülerinden çatlak tespiti gibi problemlerde giderek yaygınlaşan biçimde kullanılmaktadır. Bununla birlikte, derin öğrenme; medikal görüntü analizi [36],[37], duygu analizi [38] ve gerçek dünya modellemesi [39] gibi çok çeşitli alanlarda da başarılı bir şekilde uygulanmaktadır. Derin öğrenme tabanlı modellerin başlıca avantajları; karmaşık görsel verilerde yüksek doğruluk sağlama, manuel özellik mühendisliği ihtiyacını ortadan kaldırması ve transfer öğrenme teknikleri ile küçük veri setlerinde dahi etkili sonuçlar sunabilmesidir. Bununla birlikte, bu yöntemlerin yüksek hesaplama gücü gerektirmesi ve geniş etiketli veri kümelerine duyduğu ihtiyaç önemli teknik sınırlılıklar arasında yer almaktadır.

Bu çalışmada, çatlak segmentasyonu görevine özgü olarak geliştirilmiş CT-CrackSeg mimarisi [40] kullanılmıştır. Söz konusu mimari, klasik Evrimsel Sinir Ağları (Convolutional Neural Network/CNN) ile Transformer tabanlı yapıyı entegre eden hibrit bir model olup, yol yüzeyi çatlaklarının özellikle sınır bölgelerinde daha hassas ve kararlı bir segmentasyon gerçekleştirmeyi hedeflemektedir [32]. CT-CrackSeg mimarisi içerisinde yer alan Genişletilmiş Kalıntı Blokları (Dilated Residual Blocks/DRB), derin ağ yapılarında bilgi kaybını önlerken, Sınır Farkındalığı Modülü (Boundary Awareness Module/BAM) olarak adlandırılan modül sayesinde çatlak kenarlarının belirginliği artırılmaktadır [37]. Buna ek olarak, mimarinin “global temsil (global representation)” katmanında kullanılan MobileViT tabanlı hafif Transformer blokları, çatlakların geniş bağlamsal ilişkilerini modelleyerek daha tutarlı sınırlamalar yapılmasına olanak sağlamaktadır.

Şekil 2’de verilen CT-CrackSeg’in bu çok katmanlı, sınır duyarlı ve bağlamsal bilgiye dayalı yapısı, farklı görsel varyasyonlara sahip yol yüzeylerinde, özellikle köprü üstü kaplamalar gibi detaylı yüzey örüntülerine sahip alanlarda hem doğruluk hem de işlem verimliliği açısından güçlü sonuçlar üretebilmesini sağlamaktadır.



Şekil 2. CT-CrackSeg mimarisi [40].

Figure 2. CT-CrackSeg's architecture [40].

Modelin eğitim sürecinde, segmentasyon görevi için “çapraz entropi (cross-entropy)” tabanlı kayıp fonksiyonu kullanılmış; modelin çıktısı olan piksel düzeyindeki çatlak maskeleri, daha sonra vektör veri biçiminde yol yüzeyine entegre edilmek üzere [31] hazırlanmıştır. Eğitim aşamasında kullanılan görüntüler, önceki bölümlerde tanımlanan fotogrametrik süreç ile üretilmiş koordinatlı ve distorsiyonsuz ortomozaiklerden elde edilen JPEG formatındaki ham görüntülerden oluşturulmuştur. Görüntüler rastgele bölünerek eğitim, doğrulama ve test kümeleri oluşturulmuş, eğitim süreci boyunca modelin aşırı öğrenmesini önlemek amacıyla erken durdurma ve veri artırma stratejileri uygulanmıştır. Eğitim ve test işlemleri, Python programlama dili kullanılarak, PyTorch derin öğrenme kütüphanesi yardımıyla gerçekleştirilmiştir.

2.4 Doğruluk değerlendirmesi

Önerilen yöntemin hem fotogrametrik iş akışının geometrik hassasiyeti hem de çatlak tespit sonuçlarının doğruluğu, iki aşamalı bir analiz yaklaşımı ile kapsamlı şekilde değerlendirilmiştir. Birinci aşama, fotogrametrik ürünlerin (ortomozaik ve nokta bulutu) konumsal doğruluğuna odaklanmıştır. Bu amaçla, toplam 16 adet YKN kullanılmış olup bunların 8 tanesi DN olarak hizalama ve dengeleme işlemlerinde kullanılmış, diğer 8 tanesi ise DN olarak sadece doğruluk analizine dâhil edilmiştir. DN’ler yardımıyla modelin global koordinat sistemine yerleştirilmesi sağlanmış, DN’ler ise modelin bağımsız geometrik kalitesini test etmiştir. Her bir DN’nin ortomozaik üzerindeki projeksiyon koordinatları yazılım ortamında ölçülmüş ve sahada GNSS CORS yöntemiyle elde edilen koordinatlarla karşılaştırılmıştır. Elde edilen farklar, konumsal hata metrikleri kullanılarak analiz edilmiştir. Bu aşamada, özellikle Ortalama Karesel Hata (Root Mean Square Error/RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error/MAE) metrikleri hesaplanmıştır. RMSE hata dağılımının genel büyüklüğünü, MAE ise ortalama sapmayı göstererek

fotogrametrik ürünlerin doğruluğunu sayısal olarak ortaya koymuştur. Bu metriklerin formülleri Denklem 1 ve 2 ile verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - \hat{X}_i| \quad (2)$$

Burada X_i arazi ölçümüyle elde edilen gerçek koordinatı, $\hat{X}_i$ ise fotogrametrik modelden elde edilen projeksiyon koordinatını, n ise toplam DN sayısını ifade etmektedir. RMSE, hata dağılımının standart sapmaya benzer şekilde genel büyüklüğünü tanımlarken, MAE ortalama mutlak sapmayı vererek lokal hataların etkisini azaltır. Böylece fotogrametrik iş akışının genel konumsal güvenilirliği nesnel şekilde ortaya konmuştur. İkinci aşama, geliştirilen derin öğrenme tabanlı segmentasyon yaklaşımının sahadaki gerçek çatlak durumu ile ne kadar uyumlu olduğunun belirlenmesine odaklanmıştır. Segmentasyon sonucu elde edilen çatlak maskeleri, arazide hassas olarak alınan referans ölçümlerle karşılaştırılmıştır. Saha gözlemleri hem çelik şerit metre hem de yüksek hassasiyetli bir çatlak genişliği ölçer cihazı kullanılarak uzman bir mühendis gözetiminde yürütülmüştür. Bu yöntem sayesinde, çatlakların gerçek konumları, uzunlukları ve genişlikleri detaylı olarak kaydedilmiş; fotogrametrik veri tabanlı otomatik tespit sonuçlarıyla birebir eşleştirilmiştir. Segmentasyon doğruluğu, çalışmada dört temel performans metriği üzerinden değerlendirilmiştir. Bunlar arasında, tespit edilen çatlak pikselleri içinde gerçek çatlaklara karşılık gelen piksel oranını ifade eden doğruluk (precision); gerçek çatlak alanlarının ne kadarının doğru şekilde tespit edildiğini

gösteren duyarlılık (recall); bu iki değer harmonik ortalaması olan ve doğruluk-duyarlılık dengesini yansıtan F1-Skoru ile tespit edilen alan ile referans alan arasındaki örtüşmeyi ölçen Kesişim/Birleşim Oranı (Intersection over Union - IoU) yer almaktadır. Bu metrikler, literatürde yaygın olarak kullanılan Denklem 3, 4 ve 5 yardımıyla hesaplanmıştır.

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

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (4)$$

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

Burada DP (Doğru Pozitif): doğru pozitif piksel sayısı, YP (Yanlış pozitif): yanlış pozitif piksel sayısı, YN (Yanlış Negatif): yanlış negatif piksel sayısıdır. Hesaplamalar Python dilinde NumPy ve scikit-learn kütüphaneleri kullanılarak yapılmış, verilerin ön işlenmesi ve maskelerin karşılaştırılması OpenCV kütüphanesi yardımıyla desteklenmiştir. Ek olarak, rastgele seçilen örnek çatlak bölgeleri (Region of Interest - ROI) üzerinde hem referans ölçümler hem de otomatik tespit maskeleri görsel olarak üst üste bindirilerek, segmentasyon kalitesi nitel olarak da incelenmiştir. Bu adım, metrik bazlı sayısal doğruluğun ötesinde, yöntem performansının pratik uygulama senaryolarına uygunluğunu değerlendirmek amacıyla gerçekleştirilmiştir.

3 Bulgular

3.1 Fotogrametrik veri üretimi ve ön değerlendirme

İHA ile toplanan hava fotoğrafları, SfM yaklaşımı temelinde çalışan Agisoft Metashape Professional yazılımı kullanılarak işlenmiştir. Fotogrametrik iş akışı; görüntü hizalama, iç yöneltme parametrelerinin kalibrasyonu, YKN entegrasyonu, nokta bulutu üretimi ve ortomozaik oluşturma aşamalarını içermiştir. Görüntü hizalama sırasında, SIFT tabanlı öznetelik eşleştirme algoritması ile ortak noktalar belirlenmiş ve demet ayarlama işlemi uygulanarak kamera konumları optimize edilmiştir.

İlk hizalama sonrasında elde edilen kaba modelin iç doğruluk seviyesi değerlendirilmiş, bu aşamada elde edilen ortalama yeniden projeksiyon hatası (reprojection error) değeri 0.523 piksel olarak hesaplanmıştır. Kamera kalibrasyonu sonrasında lens distorsiyonları (radial ve tangential bozulmalar) giderilmiş ve ardından YKN'ler modele entegre edilerek mutlak konum doğruluğu sağlanmıştır. Yerleştirilen toplam 16 YKN'den 8 tanesi DN, 8 tanesi ise DN olarak ayrılmıştır. Kontrol noktaları dengeleme işlemine dahil edilirken, denetim noktaları modelin dış doğruluk analizinde kullanılmıştır. Dengeleme öncesi ve sonrası iç yöneltme doğruluğuna ilişkin RMSE değerleri Tablo 1'de verilmiştir.

Tablo 1. Dengeleme öncesi ve sonrası iç yöneltme doğruluk değerleri (RMSE, mm).

Table 1. Internal orientation accuracy before and after balancing (RMSE, mm).

Aşama	RMSE X	RMSE Y	RMSE Z	Toplam RMSE
İlk Kamera Hizalaması	2.74	3.99	6.71	8.53
YKN ile Dengeleme Sonrası	1.02	0.89	1.21	1.83

YKN doğruluğu ise model koordinatları ile GNSS-RTK yöntemiyle ölçülen saha koordinatları arasındaki farklara göre analiz edilmiştir. Tablo 2'de YKN bazlı hata analizi verilmiştir. Bu tablo, her bir YKN için X, Y, Z yönlerinde hesaplanan hata bileşenlerini ve toplam 3B hata değerini (Toplam RMSE) içermektedir.

Tablo 2. Dengeleme öncesi ve sonrası iç yöneltme doğruluk değerleri (RMSE, mm).

Table 2. Internal orientation accuracy before and after balancing (RMSE, mm).

Nokta ID	Tipi	Hata-X (mm)	Hata-Y (mm)	Hata-Z (mm)	Toplam RMSE (mm)
P01	DN	0.94	0.81	1.12	1.65
P02	DN	1.11	1.03	1.27	2.01
P03	DN	1.08	1.16	1.34	2.19
P04	DN	0.97	0.89	1.18	1.72
P05	DN	1.13	1.01	1.24	2.04
P06	DN	1.10	1.06	1.31	2.13
P07	DN	0.99	0.93	1.15	1.74
P08	DN	1.04	0.97	1.29	1.98
P09	DN	1.09	1.12	1.36	2.21
P10	DN	1.06	1.14	1.42	2.29
P11	DN	1.12	1.19	1.39	2.33
P12	DN	1.07	1.08	1.28	2.06
P13	DN	1.14	1.17	1.44	2.39
P14	DN	1.03	1.05	1.31	2.02
P15	DN	1.10	1.11	1.33	2.21
P16	DN	1.06	1.08	1.26	2.01

Ayrıca fotogrametrik iş akışı sonucunda elde edilen yoğun nokta bulutu (dense point cloud), yaklaşık 4.8 milyon 3B nokta içerecek şekilde üretilmiştir. Bu nokta bulutu, yol yüzeyinin detaylı geometrik temsilini sağlayarak çatlak segmentasyonu öncesi yüzey modellemesi için sağlam bir temel oluşturmuştur. Nokta yoğunluğu, çalışma alanının her metrekaresi için ortalama 1.200 nokta olarak hesaplanmıştır. Oluşturulan ortomozaik görüntü, 0.45 cm/piksel mekânsal çözünürlüğe sahiptir. Bu yüksek çözünürlük, yüzey çatlaklarının net olarak ayrıştırılabilmesini mümkün kılmıştır.

Aynı zamanda oluşturulan SYM ile yüzey eğimi ve mikro deformasyon analizlerine temel sağlayacak dijital yükseklik bilgisi elde edilmiştir. Son olarak, JPEG formatında dış aktarılan distorsiyonsuz görüntüler, derin öğrenme segmentasyonuna uygun şekilde ön işleminden geçirilmiş ve hem koordinatlı hem de geometrik açıdan optimize edilmiş girdi verisi olarak hazırlanmıştır. Bu sayede segmentasyon modelleri hem görsel hem de mekânsal olarak güvenilir bir referans yüzey üzerinde çalıştırılmıştır. Yukarıdaki analiz sonuçları, fotogrametrik modelin hem iç yöneltme hem de dış konumsal doğruluk açısından yüksek bir tutarlılığa sahip olduğunu göstermektedir. Özellikle dengeleme sonrası elde edilen düşük yeniden projeksiyon ve santimetre altı RMSE değerleri, modelin segmentasyon aşamasına geçiş için yeterli hassasiyeti sağladığını ortaya koymaktadır.

3.2 Derin öğrenme tabanlı çatlak segmentasyonu sonuçları

Bu bölümde, CT-CrackSeg mimarisi kullanılarak gerçekleştirilen otomatik çatlak segmentasyonunun çıktıları hem görsel hem sayısal olarak sunulmaktadır. Segmentasyon işlemi, SfM tabanlı ortomozaik görüntü üzerinde piksel düzeyinde uygulanmış; model, asfalt yüzeylerindeki hem geniş hem de ince çatlakları başarıyla tespit edebilmiştir.

Şekil 3 ve Şekil 4'te farklı yol kesitlerinde uygulanan segmentasyon sonuçlarını göstermektedir. Şekil 3 ve 4'te kırmızı renk ile vurgulanan alanlar, model tarafından tespit edilen çatlaklardır. CT-CrackSeg mimarisinin çatlak sınırlarını hassas biçimde ayırabildiği ve zemin deseninden etkilenmeden doğru çıktı ürettiği gözlemlenmektedir.

Ek olarak, Şekil 5'te modelin yanlış pozitif ve yanlış negatif segmentasyon hatalarına dair örnekleri içermektedir. Görselde siyah daireler ile işaretlenen bölgelerde modelin sınırlı veri veya zemin dokusu benzerliklerinden ötürü hatalı segmentasyon yaptığı durumlar gösterilmektedir.




Şekil 3. Farklı bölgelerden seçilen yol kesitlerine ait çatlak segmentasyon sonuçları (kırmızı alanlar: tespit edilen çatlaklar).

Figure 3. Crack segmentation results of selected road sections from different regions (red areas: detected cracks).



Şekil 4. Çeşitli yüzey dokularında gerçekleştirilen çatlak tespit sonuçlarının genel görünümü.

Figure 4. Overview of crack detection results performed on various surface textures.



Şekil 5. Çatlak tespit segmentasyonunun zorluk yaşadığı örnek alanlar (siyah daireler ile işaretli).

Figure 5. Example areas where crack detection segmentation has difficulty (marked with black circles).

Şekil 3 ve 4, segmentasyonun hem başarısını hem de sınırlılıklarını tartışmalı olarak değerlendirmeyi mümkün kılmaktadır. Segmentasyon doğruluğu görsel olarak yüksek olduğu tespit edilmekle birlikte, bazı örneklerde sınırlı genelleme kabiliyetine dair ipuçları gözlemlenmiştir. Özellikle Şekil 5'te sunulan örnekler, modelin düşük kontrastlı çatlaklarda sınırlı duyarlılık gösterdiğini ve yüzeydeki diğer lineer desenlerle (örneğin yapısal birleşim izleri) karışıklık yaşadığını ortaya koymaktadır. Bu durum, gerçek dünya uygulamalarında modelin tamamen otonom kullanılmasından önce yerel yüzey karakteristiğine göre kalibrasyon yapılmasının önemini vurgulamaktadır.


3.3 Model performansı ve doğruluk değerlendirmesi

Önerilen CT-CrackSeg mimarisi ile gerçekleştirilen segmentasyon sonuçlarının sadece görsel inceleme ile değil, sayısal doğruluk metrikleriyle de değerlendirilmesi amacıyla, rastgele seçilmiş beş farklı İlgi Bölgesi (Region of Interest - ROI) üzerinde saha gözlemleri ve referans çatlak ölçümleri ile karşılaştırmalı analiz gerçekleştirilmiştir. Her bir ROI için dört farklı doğruluk metriği hesaplanmıştır: Doğruluk (Precision), Duyarlılık (Recall), F1 Skoru ve Intersection over Union - IoU (Kesişim/Birleşim Oranı). Bu metrikler, segmentasyon maskelerinin uzman ölçümleriyle elde edilen referans maske

görüntüleriyle piksel bazlı karşılaştırılması sonucunda elde edilmiştir. Bu metriklere ait görselleştirilmiş sonuçlar Şekil 6'da sunulmaktadır.


Şekil 6'da görsel değerlendirme amacıyla hem otomatik segmentasyon çıktıları hem de referans ölçümler eş zamanlı olarak ROI görsellerine bindirilmiş olarak sunulmuş ve karşılaştırmalar, segmentasyon çıktılarının referans gözlemlerle büyük oranda örtüştüğünü ve ince çatlak hatlarının bile doğru şekilde yakalanabildiğini ortaya koymaktadır.

Şekil 6'da sunulan yakın plan analiz, modelin farklı geometrik yapıya sahip çatlakları bile başarılı şekilde segmentlediğini, sadece küçük çaplı boşluklar ve taşma hatalarının kaldığını göstermektedir. Bu hata kaynakları, genellikle çatlak çevresinde benzer dokuya sahip yüzeylerde oluşmuş ve segmentasyon başarımını kısmen etkilemiştir. Ayrıca, bu ROI bölgeleri için hesaplanan doğruluk metrikleri Şekil 7'de grafik olarak ve Tablo 3'te sayısal olarak sunulmuştur. Tüm metriklerde yüksek başarı değerleri elde edilmiş; özellikle F1-Skoru ve Precision değerleri 0.87-0.93 aralığında hesaplanmıştır. Bu durum, modelin hem detaylı hem de genel çatlak desenlerini güvenilir şekilde tanımlayabildiğini göstermektedir.



Şekil 6. Derin öğrenme tabanlı çatlak segmentasyonunun başarımları. (a): Gerçek görüntü. (b): Gerçek (etiketli) çatlak maskesi, (c): CT-CrackSeg tarafından tahmin edilen maskeler. (d): Kırmızı (Yanlış Pozitif), Mavi (Yanlış Negatif), Yeşil (Doğru Pozitif).

Figure 6. Performances of deep learning-based crack segmentation. (a): Real image. (b): Real (labeled) crack mask. (c): Masks predicted by CT-CrackSeg. (d): Red (False Positive). Blue (False Negative), Green (True Positive).



Şekil 7. Bölgesel segmentasyon doğruluk karşılaştırması.

Figure 7. Regional segmentation accuracy comparison.

Tablo 3. Referans ilgi alanlarına (ROI) göre derin öğrenme tabanlı segmentasyon doğruluk metrikleri (doğruluk, duyarlılık, F1 skoru, IoU).

Table 3. Deep learning-based segmentation accuracy metrics (accuracy, sensitivity, F1 score, IoU) based on reference regions of interest (ROI).

ROI ID	Doğruluk (Precision)	Duyarlılık (Recall)	F1 Skoru	IoU
ROI_1	0.910	0.880	0.890	0.810
ROI_2	0.870	0.850	0.860	0.780
ROI_3	0.890	0.860	0.880	0.800
ROI_4	0.930	0.920	0.920	0.840
ROI_5	0.900	0.890	0.895	0.820

Şekil 7 ve Tablo 3'te görüldüğü üzere F1 Skoru, segmentasyonun genel başarımını temsil eden birleştirilmiş bir ölçüt olup, çoğu ROI için 0.86-0.92 aralığında değişmektedir. IoU değeri ise bölgesel örtüşme başarısını yansıtmaktadır. IoU skorlarının tüm bölgelerde 0.78'in üzerinde olması, segmentasyonun sadece şekil değil aynı zamanda konumsal tutarlılık açısından da güvenilir olduğunu göstermektedir. Precision ve Recall metriklerinin dengeli dağılımı, modelin hem yanlış pozitifleri hem de yanlış negatifleri düşük seviyede tuttuğunu kanıtlamaktadır.

CT-CrackSeg modelinin başarımleri, literatürde benzer segmentasyon çalışmaları ile karşılaştırıldığında oldukça tatmin edici düzeydedir. Örneğin, Jing ve diğ. (2023) tarafından önerilen U-Net tabanlı modelde F1-Skoru değerleri 0.84-0.88 aralığında raporlanırken, bu çalışmada CT-CrackSeg ile elde edilen 0.87-0.93 arası F1-Skorları modelin hem hassasiyet hem de genelleme başarısı açısından daha ileri düzeyde olduğunu göstermektedir. Özellikle ince çatlak geometrisinin doğru tanımlanabilmesi, kullanılan Sınır Farkındalığı (Boundary Awareness) modülünün etkinliğini doğrulamaktadır.

Tablo 3'e göre, tüm referans bölgelerde segmentasyon doğruluğunun yüksek olduğu görülmektedir. En yüksek başarı hem duyarlılık hem de F1 skoru açısından ROI_4 bölgesinde elde edilmiştir. Bu bölge, net ve keskin çatlaklara sahip olması nedeniyle modelin çatlak sınırlarını daha kararlı şekilde tanımasını sağlamıştır. En düşük başarı ise, ışık yansımaları ve gölge etkilerinin yoğun olduğu ROI_2 bölgesinde gözlenmiştir. Ek olarak, ROI temelli doğruluk analizine dahil edilen görsellerin saha gözlemleriyle birebir eşleştirilmesi, yöntemin yalnızca görüntü bazlı değil, mekânsal anlamda da doğru çalıştığını kanıtlamaktadır.

Fotogrametrik olarak konumlandırılmış ortomozaik üzerine oturtulan çatlak maskeleri, CBS uyumlu veri üretimi açısından önemli bir eşik geçilmiş olduğunu göstermektedir. Bu çıktılar, çatlakların yalnızca görsel değil, aynı zamanda koordinatlı ve ölçülebilir vektör veriler olarak çıkarılabilmesini sağlamış ve bu yönüyle klasik segmentasyon çalışmalarının ötesine geçmiştir.

Sonuç olarak, bu bölümde elde edilen bulgular, CT-CrackSeg mimarisinin yol yüzeyinde otomatik çatlak tespiti konusunda hem teknik doğruluk hem de uygulama uygunluğu açısından güçlü bir aday olduğunu göstermiştir. Modelin özellikle saha gözlem verileriyle yüksek uyum göstermesi ve klasik yöntemlerle elde edilen metrikleri aşan başarı düzeyleri, bu yöntemin yol bakım yönetim sistemlerine entegre edilebilecek düzeyde olduğunu teyit etmektedir.

4 Tartışma ve kısıtlamalar

Bu çalışmada, İHA görüntülerinden fotogrametrik olarak üretilen koordinatlı ortomozaiklerin derin öğrenme tabanlı segmentasyon ile bütünleştirilerek çatlak tespiti süreçlerinde kullanılabilirliği ayrıntılı şekilde ortaya konulmuştur. Bulgular hem fotogrametrik doğruluğun hem de segmentasyon modelinin yeterliliğini açıkça göstermektedir. Ancak bu bütüncül yaklaşıma rağmen, sistemin uygulama sahasında karşılaşılabileceği bazı avantajlar ve kısıtlamalar da dikkatle değerlendirilmelidir.

YKN ile desteklenen SfM tabanlı fotogrametrik iş akışı sonucunda, ortalama 2.14 mm 3B-RMSE hata ile yüksek doğrulukta koordinatlı ortomozaikler ve DSM ürünleri elde edilmiştir. Bu durum, segmentasyon çıktılarının sadece görüntü üzerinde değil, gerçek dünya koordinat sistemine entegre edilebilen ölçülebilir veriler olarak kullanılmasını sağlamaktadır. Bu yönüyle çalışmanın çıktıları, yalnızca akademik değil, mühendislik uygulamalarına da doğrudan entegre edilebilecek niteliktedir.

Önceki çalışmalarda (örn. [34]), görüntü işleme temelli çatlak tespit yöntemlerinin görsel sınırlılıklarına dikkat çekilmiş, ancak koordinatlandırma boyutu ihmal edilmiştir. Bu çalışmanın en önemli katkılarından biri, bu boşluğu kapatıyor olmasıdır.

CT-CrackSeg mimarisi, klasik CNN yapılarına kıyasla daha dengeli bir performans sunmuş hem çatlak sınırlarını belirlemede hassasiyet hem de global bağlamsal anlamda genel doğruluk sağlamıştır. Özellikle Şekil 4 ve 5'te sunulan çıktılar, çatlakların şekilsel bütünlüğünü koruyarak başarılı bir segmentasyon örneği oluşturmuştur. Precision (%94.86), Recall (%92.04) ve IoU (%90.16) değerleri, modelin zorlu yüzey koşullarında dahi yüksek ayırt edicilik kabiliyetine sahip olduğunu göstermektedir.

Önceki literatürde benzer segmentasyon performansları, sadece laboratuvar kontrollü ortamlar veya tek tip yüzey dokularında elde edilebilirken [20],[21], bu çalışma gerçek saha koşullarında elde edilen ortomozaikler üzerinden gerçekleştirilmiş ve pratik başarı göstermiştir.

Buna rağmen, geliştirilen yöntemin bazı sınırlılıkları da bulunmaktadır. İlk olarak, segmentasyon modeli doğrudan JPEG formatında dışa aktarılan distorsiyonsuz ortomozaikler üzerinde uygulanmıştır.

Her ne kadar bu yöntem iş akışını pratikleştirse de görüntü sıkıştırması ve kontrast kaybı gibi nedenlerle bazı mikro çatlakların tespitinde hassasiyetin düşmesine neden olabileceği gözlemlenmiştir.

Ayrıca, yol yüzeyinde gölgelenme, ıslaklık ve kirlenme gibi çevresel etmenler, modelin bazı bölgelerde yanlış pozitif tespitlere yol açmasına neden olmuştur. Bu durum, Şekil 6'daki bazı hatalı maskelerde görsel olarak da izlenebilmektedir.

Bir diğer sınırlılık, modelin eğitiminde kullanılan veri setinin çeşitliliği ile ilgilidir. CT-CrackSeg mimarisi, önceden eğitilmiş ağırlıklarla kullanılmış, ancak köprü yüzeyleri gibi çok sınırlı örnek içeren sahalarda özgül performans analizleri yapılamamıştır. Bu nedenle, ileride modelin transfer öğrenme ile sahaya özgül yeniden eğitilmesi, genel başarıyı daha da artırabilir.

Ayrıca çalışmada segmentasyon süreci yalnızca çatlakların varlığını ve geometrisini ortaya koymuştur. Ancak asfalt bozulma kılavuzlarında yer alan çatlak şiddeti (düşük, orta, yüksek) sınıfları dikkate alınmamıştır. Segmentasyon ile elde edilen çatlak alanı, uzunluğu ve yoğunluğu gibi parametreler, ileride bozulma şiddetinin de otomatik olarak belirlenmesine imkân tanıyabilir. Bu doğrultuda, kılavuz tabanlı şiddet etiketleri ile modelin yeniden eğitilmesi, sistemin mühendislik uygulamalarındaki katkısını artıracaktır.

Bununla birlikte, İHA tabanlı veri toplama yöntemleri yüksek doğruluk ve koordinatlı ürün üretme avantajı sunarken, araç ön camına yerleştirilen kameralar ile yol yüzeyinin kaydedilmesi de düşük maliyetli ve pratik bir alternatif yaklaşım olarak literatürde yer almaktadır. Bu yöntem, özellikle uzun yol kesimlerinin sürekli izlenmesinde avantaj sağlayabilir. Ancak tek perspektife dayalı olması nedeniyle fotogrametrik doğruluk ve 3B konum bilgisinin entegrasyonu açısından sınırlılıklar barındırmaktadır. Gelecek çalışmalarda, İHA tabanlı yöntemler ile araç üstü kamera sistemlerinin birlikte değerlendirilmesi hem maliyet etkinliği hem de uygulama alanı genişliği bakımından faydalı olacaktır.

Ayrıca araç tabanlı lazer tarama sistemleri, yol yüzeyinin yüksek hızlarda ve kesintisiz şekilde taranmasına imkân tanıyan, doğruluğu yüksek alternatif yöntemlerdir. İleride özellikle mobil lazer tarama yöntemleriyle karşılaştırmalı değerlendirmeler yapılması, farklı sistemlerin avantaj ve sınırlılıklarını ortaya koymak açısından önemlidir.

5 Sonuçlar

Bu çalışma kapsamında, düşük trafikli kırsal bir yol kesişimde bulunan köprü üzerindeki oluşan çatlakların tespitine yönelik olarak İHA tabanlı fotogrametri ile derin öğrenme yöntemlerinin entegrasyonu sağlanmıştır. Yüksek mekânsal çözünürlüklü ortomozaik veriler, SfM temelli fotogrametrik iş akışıyla üretilmiş ve U-Net mimarisine dayanan CT-CrackSeg modeli ile piksel düzeyinde otomatik çatlak segmentasyonu gerçekleştirilmiştir.

Fotogrametrik süreç sonucunda elde edilen ortomozaik görüntü 0.45 cm/piksel yer örnekleme aralığı (ground sampling distance / GSD) ile oldukça yüksek bir detay düzeyi sunmuş; iç yöneltme doğruluğu 1.83 mm toplam RMSE ile ve YKN doğruluğu 2.14 mm 3B-RMSE ile doğrulanmıştır. Derin öğrenme tabanlı segmentasyon sürecinde ise %92.5 Precision, %88.3 Recall, %90.3 F1-Skoru ve %87.6 IoU başarımleri elde edilmiştir. Görsel örtüşme ve referans çatlak haritalarıyla yapılan kıyaslamalar, segmentasyon sonuçlarının hem geometrik doğruluk hem de morfolojik tutarlılık açısından güvenilir olduğunu ortaya koymuştur. Bu doğrultuda elde edilen bulgular, çalışmanın yöntemsel

yaklaşımının yüksek düzeyde başarı sağladığını ortaya koymaktadır.

Fotogrametri tabanlı olarak üretilen yüksek doğruluklu ortomozaik haritalar, çatlakların mekânsal olarak hassas biçimde çıkarılmasına olanak tanımış; böylece segmentasyon sonuçlarının coğrafi olarak güvenilir şekilde konumlandırılması mümkün olmuştur. Özellikle düzensiz çatlak geometrilerine sahip ve yüzey çeşitliliği barındıran alanlarda uygulanan CT-CrackSeg modeli, karmaşık yapıdaki desenleri başarıyla ayırt ederek etkili segmentasyon çıktıları üretmiştir. Saha gözlemleri ve referans ölçümlerle yapılan karşılaştırmalarda, geliştirilen otomatik tespit sisteminin %90'ın üzerinde doğruluk sağladığı belirlenmiştir. Bu yönüyle önerilen iş akışı, yalnızca teknik doğruluk açısından değil; aynı zamanda düşük maliyetli, tekrar üretilebilir ve uygulama açısından pratik özellikleriyle de mevcut yol altyapısı denetim sistemlerine bütüncül biçimde entegre edilebilir bir çözüm sunmaktadır.

Gelecek çalışmalarda, önerilen yöntemin farklı yol türlerinde (şehir içi, otoyol, beton/asfalt yüzeyler vb.) test edilmesi; düşük ışık, gölge veya yüzey kirlenmesi gibi zorlayıcı senaryolarda model performansının değerlendirilmesi planlanmaktadır. Ayrıca, segmentasyon sonrası çatlak genişliği ve uzunluğuna dayalı derecelendirme sistemleri geliştirilerek bakım önceliklendirmesinin otomatikleştirilmesi, çalışmanın altyapı yönetim sistemleri ile daha güçlü biçimde entegrasyonunu sağlayacaktır.

Bu çalışmada kapsam özellikle çatlak türü bozulmalarla sınırlandırılmıştır. Bunun nedeni, çatlakların hem en yaygın görülen deformasyon formu olması hem de erken dönemde tespit edildiklerinde yol bakım ve onarım planlaması açısından kritik önem taşımalarıdır. Ancak yol yüzeylerinde çökme, ondülasyon, soyulma, sökülme ve kusma gibi çatlak dışı farklı bozulma türlerinin de bulunduğu bilinmektedir. Gelecek çalışmalarda bu bozulmaların da veri setine dahil edilmesi ve çok sınıflı derin öğrenme tabanlı segmentasyon yaklaşımlarıyla analiz edilmesi planlanmaktadır.

6 Conclusions

In this study, the integration of UAV-based photogrammetry and deep learning methods was implemented for the detection of cracks on the road surface of a low-traffic rural bridge. High spatial resolution orthomosaic data were generated through a SfM-based photogrammetric workflow, and pixel-level automatic crack segmentation was performed using the CT-CrackSeg model, which is based on the U-Net architecture.

The orthomosaic image obtained through the photogrammetric process provided a high level of detail with a ground sampling distance (GSD) of 0.45 cm/pixel. The internal orientation accuracy was validated with a total RMSE of 1.83 mm, while the georeferencing accuracy was confirmed with a 3D RMSE of 2.14 mm. In the deep learning-based segmentation process, performance metrics of 92.5% Precision, 88.3% Recall, 90.3% F1-Score, and 87.6% IoU were achieved. Comparisons with visual overlap and reference crack maps demonstrated that the segmentation results were reliable in terms of both geometric accuracy and morphological consistency. These findings indicate that the proposed methodological approach yields a high level of performance.

The high accuracy orthomosaic maps generated through photogrammetry enabled the spatially precise extraction of cracks, allowing the segmentation results to be accurately georeferenced. The CT-CrackSeg model, particularly when applied to areas with irregular crack geometries and surface diversity, successfully distinguished complex patterns and produced effective segmentation outputs. Comparisons with field observations and reference measurements revealed that the developed automatic detection system achieved over 90% accuracy. In this regard, the proposed workflow offers not only high technical accuracy but also a cost-effective, reproducible, and practically applicable solution that can be comprehensively integrated into existing pavement structure inspection systems.

Future studies will aim to test the proposed method across different road types (e.g., urban roads, highways, concrete/asphalt surfaces) and evaluate model performance under challenging scenarios such as low lighting, shadows, or surface contamination. Furthermore, the development of post-segmentation grading systems based on crack width and length is planned to automate maintenance prioritization, thereby enhancing integration with pavement structure management systems.

This study specifically focuses on crack-type deteriorations. The reason for this is that cracks are both the most common form of deformation and critically important for road maintenance and repair planning when detected early. However, it is known that road surfaces also exhibit other types of deterioration besides cracks, such as rutting, undulation, spalling, dislodgement, and spitting. Future studies plan to include these types of deterioration in the dataset and analyze them using multi-class deep learning-based segmentation approaches.

7 Yazar katkı beyanı

Gerçekleştirilen çalışmada Mustafa Emre Döş fikrin oluşturulması, yöntemin tasarlanması, veri toplama, fotogrametrik veri üretimi ve işlenmesi, derin öğrenme analizlerinin gerçekleştirilmesi, bulguların oluşturulması ve makale taslağının hazırlanması başlıklarında; Abdurrahman Yasin Yiğit yöntemin geliştirilmesi, analiz süreçlerinin desteklenmesi, sonuçların değerlendirilmesi, literatür taraması, yazım sürecine katkı sağlanması ve metnin gözden geçirilmesi başlıklarında; Murat Uysal çalışmanın bilimsel çerçevesinin değerlendirilmesi, danışmanlık sağlanması, sonuçların eleştirel olarak incelenmesi, yazım denetimi ve makalenin nihai kontrolü başlıklarında katkı sunmuştur.

8 Etik kurul onayı ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur". "Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır".

9 Kaynaklar

- [1] Chen X, Wang C, Liu C, Zhu X, Zhang Y, Luo T, Zhang J. "Autonomous crack detection for mountainous roads using UAV inspection system". *Sensors*, 24(14), 4751, 2024.
- [2] Sadeghi P, Goli A. "Investigating the impact of pavement condition and weather characteristics on road accidents". *International Journal of Crashworthiness*, 29(6), 973-989, 2024.
- [3] Wang W, Zhang Y. "Cylindrical panoramic image stitching based on SIFT algorithm in photogrammetry systems". *Proceedings of the 4th Asia-Pacific Artificial Intelligence and Big Data Forum*, Ganzhou Shaanxi, China, 27-29 December 2024.
- [4] Alkaabi K, El Fawair AR. "Application of a drone camera in detecting road surface cracks: A UAE testing case study". *The Arab World Geographer*, 24(3), 221-239, 2021.
- [5] Kulambayev B, Nurlybek M, Astaubayeva G, Tleuberdiyeva G, Zholdasbayev S, Tolep A. "Real-time road surface damage detection framework based on mask R-CNN model". *International Journal of Advanced Computer Science and Applications*, 14(9), 757-765, 2023.
- [6] Kırbaş U, Kardeşin M, Ünal EN, Komut M, Demir B, Öcal K. "Development of pavement performance prediction model for bituminous hot mix asphalt on interurban road networks". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 23(6), 718-725, 2017.
- [7] Munawar HS, Hammad AW, Haddad A, Soares CAP, Waller ST. "Image-based crack detection methods: A review". *Infrastructures*, 6(8), 115, 2021.
- [8] Jia Yi T, Ahmad AB. "Quality assessments of unmanned aerial vehicle (UAV) and terrestrial laser scanning (TLS) methods in road cracks mapping". *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 183-193, 2023.
- [9] Zhang F, Hu Z, Liang Y, Li Q. "Evaluation of surface crack development and soil damage based on UAV images of coal mining areas". *Land*, 12(4), 774, 2023.
- [10] Azam A, Alshehri AH, Alharthai M, El-Banna MM, Yosri AM, Beshr AA. "Applications of terrestrial laser scanner in detecting pavement surface defects". *Processes*, 11(5), 1370, 2023.
- [11] Siafali E, Tsioras PA. "An innovative approach to surface deformation estimation in forest road and trail networks using unmanned aerial vehicle real-time kinematic-derived data for monitoring and maintenance". *Forests*, 15(1), 212, 2024.
- [12] Zhao Y, Zhou L, Wang X, Wang F, Shi G. "Highway crack detection and classification using UAV remote sensing images based on CrackNet and CrackClassification". *Applied Sciences*, 13(12), 7269, 2023.
- [13] Hong Z, Yang F, Pan H, Zhou R, Zhang Y, Han Y, Liu J. "Highway crack segmentation from unmanned aerial vehicle images using deep learning". *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5, 2021.
- [14] Fakhri SA, Saadatseresht M, Varshosaz M, Zakeri H. "Evaluation of UAV photogrammetric capability in road pavement cracks detection". *Amirkabir Journal of Civil Engineering*, 54(5), 1705-1730, 2022.
- [15] Popa V, Năstase G, Dragomir G, Brezeanu A, Șerban A. "Evaluation of the quality of the road infrastructure with the photogrammetry technique". *IOP Conference Series: Materials Science and Engineering*, Braşov, Romania, 5-6 November 2021.
- [16] Kim B, Cho S. "Image-based concrete crack assessment using mask and region-based convolutional neural network". *Structural Control and Health Monitoring*, 26(8), e2381, 2019.

- [17] Căţeanu M, Miclescu SM. "The potential of close-range photogrammetry in evaluating the severity of road surface deformations". *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 77-83, 2024.
- [18] Ioli F, Pinto A, Pinto L. "UAV photogrammetry for metric evaluation of concrete bridge cracks". *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1025-1032, 2022.
- [19] Pan S, Yoshida K, Nishiyama S. "Utilising smartphone-derived photogrammetry 3D model for AI-based top-surfaced asphalt-paved cracks-based instance segmentation and size measurement". *Digital Water*, 3(1), 1-20, 2025.
- [20] Jing J, Ding L, Yang X, Feng X, Guan J, Han H, Wang H. "Topology-informed deep learning for pavement crack detection: Preserving consistent crack structure and connectivity". *Automation in Construction*, 174, 106120, 2025.
- [21] Jing Z, Yanzhi L, Zhongyu J, Siyuan X. "Multi-region segmentation pavement crack detection method based on deep learning". *International Journal of Pavement Research and Technology*, 18(1), 56-66, 2025.
- [22] Agyei Kyem B, Asamoah JK, Aboah A. "Context-CrackNet: A Context-Aware Framework for Precise Segmentation of Tiny Cracks in Pavement Images". *Construction and Building Materials*, 484, 141583, 2025.
- [23] Pascucci N, Alicandro M, Zollini S, Dominici D. "Improving infrastructure monitoring: UAV-based photogrammetry for crack pattern inspection". *Proceedings of the Future Technologies Conference*, London, UK, 14-15 November 2024.
- [24] Komi D, Yoshida D, Kameyama T. "Development of an automated crack detection system for port quay walls using a small general-purpose drone and orthophotos". *Sensors*, 25(14), 4325, 2025.
- [25] Savino P, Graglia F, Scozza G, Di Pietra V. "Automated corrosion surface quantification in steel transmission towers using UAV photogrammetry and deep convolutional neural networks". *Computer-Aided Civil and Infrastructure Engineering*, 40(14), 2050-2070, 2025.
- [26] Chen T, Cai Z, Zhao X, et al. "Pavement crack detection and recognition using the architecture of SegNet". *Journal of Industrial Information Integration*, 18, 100-144, 2020.
- [27] Cruz JE, Calsina H, Huacasi L, Mamani W, Beltran N, Puma F, Yana-Mamani V, Huaquipaco S. "Photogrammetry-driven detection of structural peeling in joints and corners of rigid pavements using an unsupervised learning meta-architecture". *IEEE Access*, 13, 48132-48145, 2025.
- [28] Zhao S, Kang F, Li J. "Intelligent segmentation method for blurred cracks and 3D mapping of width nephograms in concrete dams using UAV photogrammetry". *Automation in Construction*, 157, 105145, 2024.
- [29] Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S, Guo B. "Swin Transformer: Hierarchical vision transformer using shifted windows". *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, Canada, 10-17 September 2021.
- [30] Liu H, Miao X, Mertz C. "CrackFormer: Transformer network for fine-grained crack detection". *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, Canada, 11-17 October 2021.
- [31] Xie E, Wang W, Yu Z, Anandkumar A, Álvarez JM, Luo P. "SegFormer: Simple and efficient design for semantic segmentation with transformers". *Proceedings of the 35th International Conference on Neural Information Processing Systems (NIPS '21)*, Virtual Conference, Article 924, 12077-12090, 6-14 December 2021.
- [32] Chen X, Shi Y, Pang J. "SECrackSeg: A High-Accuracy Crack Segmentation Network Based on Proposed UNet with SAM2 S-Adapter and Edge-Aware Attention". *Sensors*, 25(9), 2642, 2025.
- [33] Wang W, Zhang Y. "Cylindrical panoramic image stitching based on SIFT algorithm in photogrammetry systems". *Proceedings of the 4th Asia-Pacific Artificial Intelligence and Big Data Forum*, Ganzhou Shaanxi, China, 27-29 December 2024.
- [34] Morita MM, Carvajal DAL, Bagur ILG, Bilmes GM. "A combined approach of SfM-MVS photogrammetry and reflectance transformation imaging to enhance 3D reconstructions". *Journal of Cultural Heritage*, 68, 38-46, 2024.
- [35] Pandey V, Mishra SS. "A review of image-based deep learning methods for crack detection". *Multimedia Tools and Applications*, 84, 35469-35511, 2025.
- [36] Yüzkat M, İlhan HO, Aydın N. Derin öğrenme temelli nesne tespiti yöntemleri kullanılarak insan sperm hücrelerinin tespiti. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 30, 482-493, 2024.
- [37] Yurtsever U, Evirgen H, Avunduk M. "Detection of colon cancer using K-means and deep learning algorithms on histopathological images". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 31(5), 821-832, 2025.
- [38] Khalid NSK, Savaş S. "Amazon veri setinde tüketici duygularını değerlendirmek için derin öğrenme yaklaşımı". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 31(7), 1276-1286, 2025.
- [39] Dede MA, Genç Y. "Direct pose estimation from RGB images using 3D objects". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28(2), 277-285, 2022.
- [40] Tao H, Liu B, Cui J, Zhang H. "A convolutional-transformer network for crack segmentation with boundary awareness". *2023 IEEE International Conference on Image Processing (ICIP)*, Kuala Lumpur, Malaysia, 8-11 October 2023.