



Derin Öğrenme ile İHA Görüntüleri Tabanlı Yığma Duvar Segmentasyonu

Ozan Öztürk *¹

¹ Recep Tayyip Erdoğan Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Rize, Türkiye, ozan.ozturk@erdogan.edu.tr

Kaynak Göster: Ozturk, O. (2026). Derin Öğrenme ile İHA Görüntüleri Tabanlı Yığma Duvar Segmentasyonu. Geomatik, 11(1), 120-128.

DOI: 10.29128/geomatik.1801243

Anahtar Kelimeler

Yığma Duvar
Segmentasyonu
Kültürel Miras
Derin Öğrenme
İnsan Hava Araçları (İHA)

Araştırma Makalesi

Geliş: 10.10.2025
Reviz: 22.10.2025
Kabul: 06.11.2025
Yayınlanma: 01.04.2026



Öz

Yığma taş duvarların belgelenmesi, kültürel mirasın ve dolayısıyla tarihi yapılar hakkındaki önemli bilgilerin korunması açısından büyük önem taşımaktadır. Ancak bu tür yapıların belgelendirilmesi hem fiziksel erişim kısıtları hem de yapı elemanlarının biçimsel çeşitliliği nedeniyle çeşitli zorlukları barındırmaktadır. Bu çalışmada, İHA görüntüleri aracılığıyla yığma taş duvarların segmentasyonunu gerçekleştirmek üzere U-Net tabanlı bir derin öğrenme yöntemi önerilmektedir. Çalışma, Rize il sınırları içerisinde bulunan Zil Kale'nin İHA ile elde edilen görüntüleri üzerinde gerçekleştirilmiştir. Derin öğrenme model eğitimi için doğal ve restore edilmiş duvar yüzeylerinden oluşturulan iki farklı veri seti oluşturulmuştur. Eğitimlerden elde edilen sonuçlara göre, restore edilmiş yüzeylerde hem Recall hem de F1-Score metriklerinde %93 düzeyine ulaşılmıştır. Daha karmaşık arka planlara sahip doğal yüzeylerde ise %88 Recall ve %86 F1-Score değerleri ile modelin bu çeşitliliği de yeterli düzeyde algılayabildiği gözlemlenmiştir. Ayrıca görsel analizler, modelin hem doğal hem de düzensiz yüzeylerde taş kenarlarını hassas bir biçimde yakaladığını, taş geometrisinin tutarlı biçimde korunduğunu ve arka plan karmaşıklığından sınırlı düzeyde etkilendiğini göstermektedir. Bu nicel ve niteliksel sonuçlar yaklaşımın farklı yığma duvar tiplerinde uygulanabilir olduğunu ortaya koymaktadır. Derin öğrenme tabanlı segmentasyon yöntemlerinin kültürel miras belgelenmesine entegre edilebileceğini ve İHA destekli görüntüleme süreçlerinin saha kaynaklı sınırlamaları önemli ölçüde azaltılabileceğini göstermektedir.

UAV Image-Based Masonry Wall Segmentation with Deep Learning

Keywords

Masonry Wall Segmentation
Cultural Heritage
Deep Learning
Unmanned Aerial Vehicles (UAVs)

Research Article

Received: 10.10.2025
Revised: 22.10.2025
Accepted: 06.11.2025
Published: 01.04.2026

Abstract

The documentation of stone masonry walls is essential for protecting cultural heritage and, by extension, preserving historical information about these structures. However, such documentation is challenging due to physical access restrictions and the morphological diversity of building elements. This study proposes a U-Net-based deep learning approach to automatically segment stone masonry walls from high-resolution façade imagery captured by an unmanned aerial vehicle (UAV). Experiments were conducted on UAV imagery acquired at Zil Kale in Rize Province, Türkiye. The deep learning model was trained on two datasets comprising natural and restored wall surfaces. Both recall and F1-score exceeded 93% on restored surfaces. On natural surfaces with more complex backgrounds, reached recall of 88% and F1-score of 86%, and the model remained robust across these conditions. Visual analyses further show that the model precisely delineates stone edges, preserves stone geometry, and is only moderately affected by background clutter. The quantitative and qualitative results confirm the applicability of the proposed approach across different masonry wall types. Moreover, the integration of deep learning-based segmentation into cultural heritage documentation, supported by UAV-based imaging, can substantially mitigate on-site limitations.

1. Giriş

Kültürel mirasın belgelenmesi, tarihsel bilgi birikiminin sürekliliğini sağlaması için kritik bir rol oynamaktadır [1-5]. Bu tür koruma belgeleri, mimarlar ve koruma uzmanları için müdahale kararlarının teknik ve estetik açıdan gerekçelendirilmesini katkı sağlamaktadır. Ayrıca sanat tarihçileri ve arkeologlar için yapının dönemsel özelliklerini, işçilik tekniklerini ve bağlamsal ilişkilerini analiz edebilme imkanı da sunmaktadır. Mühendisler açısından ise taş dizilimleri, malzeme özellikleri ve yapısal süreklilik gibi unsurların belgelenmesi, dayanım ve hasar analizi gibi teknik değerlendirmeler için önemli bir veri kaynağıdır [6].

Belgeleme sürecin güvenilirliği ise belgeleme çalışmalarının sistematik, tekrarlanabilir ve yüksek doğrulukla yürütülmesine bağlıdır[7]. Özellikle kale gibi anıtsal yapılar hem mimari karmaşıklıkları hem de taşdıkları tarihsel anlam nedeniyle, yapı ölçeğinde geliştirilen ayrıntılı belgeleme yaklaşımlarına ihtiyaç duymaktadır [8]. Bu yapılarda yaygın olarak görülen taş örgülü yığma duvarlar, taş diziliminde ve biçimsel özelliklerinde gözlenen yapısal çeşitlilik nedeniyle, belgelemeye özel yaklaşımlar gerektirmektedir [9].

Belgeleme sürecinde, yapının bulunduğu fiziksel çevre koşullarına uyum sağlama sürecinde karşılaşılan teknik ve operasyonel sınırlılıklar, özellikle yığma duvar örneklerinde belirgin biçimde ortaya çıkmaktadır. Ayrıca, taşların geometrik çeşitliliği ve yapıların yer aldığı fiziksel koşullar, belgeleme sürecini teknik ve uygulamalı yönleriyle güçlendirmektedir. Günümüzde hala yaygın biçimde kullanılan geleneksel yöntemler, veri toplama ve analiz aşamalarında yüksek zaman maliyetlerine yol açmakta ve sürecin genel verimliliğini düşürmektedir [6]. Bu yöntemlerin büyük ölçüde uzman yorumuna bağlı olması da standartlaştırılabilir uygulama senaryolarının geliştirilmesini zorlaştırmaktadır [10, 11]. Bu sınırlamaları aşmak amacıyla son yıllarda gerçekleştirilen çalışmalar, görüntüler üzerinden taşların otomatik segmentasyonuna (bölütleme) odaklanmaktadır [12, 13].

Yığma duvarların taş bazında segmentasyonu için çeşitli otomatik ve yarı otomatik yöntemler geliştirilmiştir. Bu yöntemler, k-en yakın komşu (k-NN) sınıflandırıcısı ve gradyan tabanlı köşe yakalama yaklaşımları gibi yarı otomatik tekniklerden [14, 15], renkli lazer tarayıcı verilerine uygulanan iki boyutlu sürekli dalgacık dönüşümü (CWT) gibi daha karmaşık analiz stratejilerine kadar uzanmaktadır [16]. Başarılı sonuçlar elde edilmiş olsa da istenen doğruluk ve genellenebilirlik düzeylerine ulaşmakta güçlükler devam etmektedir. Bu amaçla, yüzey düzensizlikleri ve aydınlatma değişkenliğine bağlı doğruluk kayıplarını azaltmak için derin öğrenme tabanlı yaklaşımlar giderek yaygınlaşmaktadır [17, 18]. U-Net gibi evrimsel sinir ağı mimarilerine dayalı yöntemlerin, obje segmentasyonu çalışmalarında sağladığı yüksek performans, yığma duvar segmentasyonu açısından umut verici sonuçlar ortaya koymaktadır. İbrahim ve diğ. [19], U-Net tabanlı bir model önermiştir ve model çıktıları üzerinde uygulanan watershed algoritması sayesinde

segmentasyon sonuçlarında anlamlı iyileştirmeler sağlanmıştır.

Yığma duvarlardaki taşların belgelenmesine ilişkin mevcut zorluklar yalnızca görüntü işleme tekniklerinden kaynaklanmamaktadır. Veri toplama biçimi de yığma yapıların belgelenmesine yönelik sistematik ve sürdürülebilir süreçlerin oluşturulmasını güçlendirmektedir. Bu durum, sürecin verimliliğini ve tekrarlanabilirliğini olumsuz etkilemektedir [20]. Ayrıca dar alanlar, sınırlı fiziksel erişim kısıtlamakta ve yapısal kırılabilirlik gibi saha koşullarına bağlı etmenler, veri toplama sürecini hem operasyonel hem de teknik açıdan daha karmaşık bir hale getirmektedir. Bu sınırlamaları aşmak için son dönemdeki çalışmalar, veri toplamada insansız hava araçlarını (İHA) öne çıkarmaktadır [21, 22].

İHA'lar, yüksek çözünürlüklü görüntüleri temassız ve kısa sürede elde etme imkanı sunarak, zorlayıcı çevre koşullarında dahi güvenli ve etkili veri teminini mümkün kılmaktadır [23]. İHA kullanımı, yalnızca fiziksel erişim ihtiyacını ortadan kaldırmakla kalmaz, aynı zamanda veri toplama süresini ve operasyonel yükü de belirgin biçimde azaltmaktadır [24-26]. Bu doğrultuda, İHA görüntülerinin yığma duvar segmentasyonuna entegre edilmesi, belgeleme sürecinde hem doğruluk düzeyini hem de sürecin genel verimliliğini artırma potansiyeline sahiptir [27].

Bu çalışmada, İHA ile elde edilen görüntüler kullanılarak tarihi kale duvarlarının farklı yüzey biçimlerinin belgelenme olanakları incelenmiştir. Bu kapsamda, segmentasyon sürecinde yüksek doğruluk sağlayan derin öğrenme tabanlı bir yöntem kullanılmış ve önerilen yöntemin, kültürel miras belgelemesine yönelik mevcut iş akışlarını özellikle taş yüzey ayrıştırması açısından nasıl destekleyebileceği değerlendirilmiştir. Yaklaşımın performansı, arka plan karmaşıklığı açısından farklılık gösteren iki ayrı taş yüzeyi üzerinde yapılan analizlerde test edilmiştir. Bu sayede yalnızca segmentasyon başarısı değil, yöntemin farklı fiziksel koşullarda sürdürülebilirliği ve genellenebilirliği de kapsamlı biçimde ele alınmıştır.

2. Veri ve Yöntem

Tarihi bir yığma kale yapısına ait cephe görüntüleri, İHA teknolojisi kullanılarak elde edilmiştir. Bu görüntüler, derin öğrenme tabanlı segmentasyon modellerinde kullanılmadan önce çeşitli ön işleme adımlarına tabi tutulmuştur. Taşların segmentasyonuna yönelik olarak U-Net mimarisi tercih edilmiş ve model, arka plan karmaşıklığı bakımından farklılık gösteren iki yüzey tipi üzerinde ayrı ayrı eğitilmiştir. Eğitim aşamasında, modelin genelleme kapasitesini artırmaya yönelik gelişmiş optimizasyon stratejisi uygulanmıştır. Elde edilen sonuçların doğruluğu, yaygın olarak kullanılan segmentasyon metrikleri ile test edilmiştir.

2.1. Çalışma alanı

Zil Kale, Türkiye'nin Karadeniz Bölgesi'nde yer alan Rize ilinin Çamlıhemşin ilçesinde, Fırtına Deresi vadisine tepeden bakan bir konumda bulunmaktadır. 14. ve 15.

yüzyıllarda taş yığma teknikleriyle inşa edilen yapı, anıtsal nitelikte olup birinci derece arkeolojik sit alanı olarak tescillenmiştir. Yapı, dış ve orta surların yanı sıra bir şapel, nöbetçi odası ve merkezi kuleden oluşan iç kaleyi içermektedir. Doğu cephesinde kemerli pencereler, diğer cephelerde ise mazgal açıklıkları görülmektedir. Tüm cepheler doğal taştan inşa edilmiştir ve taşlar boyut ve yüzey dokusu açısından çeşitlilik göstermektedir [28]. Bu çalışmanın odaklandığı alan, kale cephelerini ve dış surları kapsamaktadır. Çalışma alanına ilişkin İHA görüntüsü Şekil 1’de sunulmuştur.



Şekil 1. Zil Kale’ye ait cepheleri ve dış surları gösteren çalışma alanı görünümü.

2.2. Veri toplama ve ön işleme

Yığma duvarlara ait görüntüler, DJI Phantom 4 model İHA kullanılarak elde edilmiştir. 1/2.3” CMOS sensöre sahip bu cihaz, 4000x3000 piksel çözünürlükte görüntü kaydı yapabilmektedir. Cephe detaylarının bütüncül biçimde algılanabilmesi amacıyla küresel tipte bir uçuş planı uygulanmıştır. Ayrıca objeye sabit mesafeden yapılan görüntü alımı sayesinde tüm görüntüler tutarlı bir yer örnekleme aralığı (GSD – Ground Sample Distance) sağlanması hedeflenmiştir. Ortalama 10 metre mesafeden gerçekleştirilen uçuşlar sonucunda elde edilen görüntülerde yer örnekleme aralığı yaklaşık 0.31metre/piksel olarak hesaplanmıştır.


Görüntüleme işlemi ardından elde edilen İHA görüntüleri, yüzey durumlarına göre doğal ve restore edilmiş yığma duvarlar olmak üzere iki gruba ayrılmıştır. Bu görüntüler, model eğitimi sürecinde kullanılmak üzere 256x256 piksel boyutlarında alt görüntü parçalarına bölünmüştür.

Model eğitimlerinin gerçekleştirebilmesi amacıyla her görüntü için bölütleme maskeleri oluşturulmuştur. Bu işlem için başlangıçta Apeer olarak bilinen ve daha sonra Carl Zeiss Microscopy GmbH tarafından Arivis Cloud adıyla yeniden yapılandırılan çevrimiçi platform kullanılmıştır. Taş ve arka plan olmak üzere iki sınıfa karşılık gelecek şekilde maskeler hazırlanmış ve her

görüntüye ait ikili duvar görüntüsü ve segmentasyon maskeleri oluşturulmuştur.

Maskeleme işlemi, Arivis Cloud platformu üzerinde taş sınırlarının taş bazında elle müdahale gerektiren bir biçimde etiketlenmesiyle gerçekleştirilmiştir. Platformun yarı otomatik yapısı sayesinde, başlangıçta kullanıcı tarafından etiketlenen örneklerden öğrenilerek sonraki görüntülerde taş kenarlarına yönelik otomatik öneriler sunulmuştur. Bu özellik, etiketleme sürecinin hem hızını hem de tutarlılığını artırmıştır. Oluşturulan maskelerin doğruluğu, her görüntü için manuel kontrol edilerek denetlenmiştir.

Sonuç olarak, doğal yüzeylerden 260, restore edilmiş yüzeylerden ise 200 görüntü ve her bir görüntüye ait segmentasyon maskesi üretilmiştir. Bu veri setine ait örnek görseller Şekil 2’de sunulmaktadır.




Şekil 2. Farklı yüzey türlerinden örnek görüntüler ve taş sınırlarını gösteren (mavi) segmentasyon maskeleri.

2.3. U-Net mimarisi

U-Net, ilk olarak biyomedikal segmentasyon amacıyla geliştirilmiş bir evrişimli sinir ağı (convolutional neural network) mimarisidir. Biyomedikal görüntülerde objeleri yüksek doğrulukla ayrıştırabilmesi sayesinde segmentasyon görevlerinde öne çıkmış ve zamanla farklı alanlardaki segmentasyon problemlerine başarıyla entegre edilmiştir. U-Net mimarisi, kültürel mirasın belgelenmesine yönelik araştırmalarda ise son yıllarda sınırlı da olsa kullanım alanı bulmaya başlamıştır [17, 19, 29].

U-Net [30]'in yapısı, simetrik bir U harfini andıran bir mimari yapı ile tanımlanmaktadır. U-Net mimarisine ilişkin genel yapı Şekil 3'te gösterilmiştir. Bu yapı, kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bileşenden oluşmaktadır. Bu çift yönlü yapı, segmentasyon doğruluğunu artırmaya yönelik etkili bir modelleme yaklaşımı sunmaktadır. Kodlayıcı, evrişim (convolution) ve maksimum havuzlama (max pooling) katmanları aracılığıyla giriş görüntüsünden bağlamsal bilgi (contextual information) çıkartılmasını sağlamaktadır. Her bir katmanda öznetelik haritalarının (feature maps) uzamsal boyutları kademeli olarak azalırken, kanal sayısı artmaktadır. Bu aşamada model, önceki katmanlarda öğrenilen örüntülerden anlamlı temsiller türetmeye başlamaktadır.



Şekil 3. U-Net mimarisi [30].

Çözücü blokta ise, çıkartılan öznetelikleri kullanarak segmentasyon haritalarını yeniden inşa edilmektedir. Her aşamada uygulanan yukarı örnekleme (upsampling) işlemleriyle uzamsal çözünürlük kademeli olarak artırılmaktadır. Ayrıca kodlayıcı ve çözücü bileşenleri arasında kurulan atlama bağlantıları (skip connections), düşük seviyeli konumsal bilgilerin korunmasını sağlamaktadır. Böylece hem detay seviyesindeki uzamsal bilgiler hem de genel yapısal bağlam bir araya getirilerek segmentasyon çıktısının doğruluğuna anlamlı katkı sağlanmaktadır.

2.4. Değerlendirme metrikleri

Model performansını değerlendirmek amacıyla, hiper parametre ayarlamaları ve nihai doğrulama dahil olmak üzere farklı aşamalarda çeşitli değerlendirme ölçütleri kullanılmıştır. Bu çalışmada dikkate alınan metrikler arasında Precision, Recall, F1-Score ve Intersection over

Union (IoU) yer almaktadır. Bu metriklerin her biri, aşağıda verilen matematiksel ifadelerle tanımlanmaktadır.

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1-Score} = \frac{2TP}{2TP + FP + FN}$$

$$\text{IoU} = \frac{TP}{TP + FP + FN}$$

Burada, TP doğru pozitif, FP yanlış pozitif ve FN ise yanlış negatif piksel sayılarını ifade etmektedir.

2.5. Model eğitiminin yapılandırması ve hiper parametre düzenlemeleri

Etkili ve genellenebilir bir segmentasyon modeli oluşturmak amacıyla kapsamlı bir analiz süreci uygulanmıştır. Bu kapsamda, 200 görüntü doğal yüzeylerden, 260 görüntü ise restorasyon uygulanmış yüzeylerden oluşan veri seti, eğitim, doğrulama ve test alt setlerine sırasıyla %70, %15 ve %15 oranlarında ayrılmıştır. Eğitim sürecinde veri çeşitliliğini artırmak ve modelin genelleme kapasitesini güçlendirmek amacıyla çeşitli veri artırma (data augmentation) teknikleri uygulanmıştır. Bu işlemler, yatay ve dikey çevirme (horizontal and vertical flipping), rastgele döndürme (random rotation), kaydırma (shifting) ve ölçekleme (scaling) gibi geometrik dönüşümleri içermektedir. Buna ek olarak, parlaklık ve kontrast ayarı, renk bozulması (color jittering) ve Gauss bulanıklığı (Gaussian blur) gibi görsel düzeydeki dönüşümler de uygulanmıştır. Tüm görüntüler, modelin istikrarlı öğrenmesini sağlamak amacıyla ImageNet ortalama ve standart sapma değerleriyle normalize edilmiştir.

Segmentasyon modeli, Segmentation Models PyTorch [31] kütüphanesi kullanılarak oluşturulmuştur. U-Net mimarisi içerisinde encoder olarak ResNet50 ve ResNet101 yapıları entegre edilmiştir. Modelin, ImageNet [32] veri kümesi ile önceden eğitilmiş (pre-trained) ağırlıklarla başlatılan versiyonu ile tüm ağırlıkları rastgele başlatılan versiyonu karşılaştırmalı olarak değerlendirilmiştir. Hiper parametre optimizasyonu, Optuna [33] kütüphanesi kullanılarak gerçekleştirilmiştir. Her iki veri seti için en uygun yapılandırmayı belirlemek amacıyla çok sayıda parametre kombinasyonu sistematik biçimde test edilmiştir.

Model, 4'lük mini yığın boyutu (batch size) ile 100 epok (epoch) süresince eğitilmiştir. Eğitim sürecinde Binary Cross-Entropy (BCE) ve Dice Loss olmak üzere iki farklı kayıp fonksiyonu ayrı ayrı değerlendirilmiş ve model performansına etkileri karşılaştırılmıştır. Optimizasyon algoritması olarak Adam ve momentumlu Stochastic Gradient Descent (SGD) algoritmaları test edilmiştir. Öğrenme oranı (learning rate) ise 10^{-6} ile 10^{-2} aralığında logaritmik ölçekte örneklenerek belirlenmiştir. En başarılı konfigürasyonlar, doğrulama

veri seti üzerinde hesaplanan Intersection over Union (IoU) skorlarına göre seçilmiştir. Doğal ve restore edilmiş taş yüzeylerine ait veri setlerinde kullanılan hiper parametre aralıkları ve seçilen değerler Tablo 1'de verilmiştir.

Tablo 1. Her bir veri kümesi için hiper parametrelerin test edilen değer aralıkları ve belirlenen değerler.

Parametre	Test Aralığı	Belirlenen (Doğal)	Belirlenen (Restore Edilmiş)
Optimizasyon Algoritması (Optimizer)	Adam, SGD	Adam	SGD
Öğrenme Oranı (Learning Rate)	10^{-6} – 10^{-2}	1×10^{-4}	5×10^{-4}
Kayıp Fonksiyonu (Loss Function)	BCE, Dice	BCE	Dice
Kodlayıcı Mimarisi (Encoder Architecture)	ResNet50, ResNet101	ResNet50	ResNet101

3. Bulgular ve Tartışma


Bu çalışmada, derin öğrenme tabanlı segmentasyon yönteminin farklı yığma duvar yüzey tipleri üzerindeki tutarlılığı değerlendirilmiştir. Doğal ve restorasyon geçirmiş yüzeylerden elde edilen görüntülerle gerçekleştirilen testlerde, doğal yüzeyler için 50, restore edilmiş yüzeyler için ise 40 görüntü test görüntüsü olarak ayrılmıştır. Model eğitimlerinden elde edilen performans metrikleri Tablo 2'de sunulmuştur. Model, restore edilmiş yüzeylerde %92'nin üzerinde Precision, Recall ve F1-score değerlerine ulaşarak yığma duvar segmentasyonunda yüksek bir başarı sergilemiştir. Doğal yüzeylerde ise bu metriklerde yalnızca %5 ila %7 arasında bir düşüş gözlemlenmiştir. Bu durum, modelin daha karmaşık dokudaki yapılara sahip yüzeylerde dahi taş segmentlerini etkili biçimde ayırt edebildiğini göstermektedir. Sonuçlar genel değerlendirmesinde, modelin özellikle yüzey dokusu daha düzenli ve homojen olan bölgelerde daha yüksek doğrulukla segmentasyon gerçekleştirdiği görülmektedir.

Tablo 2. Modelin iki farklı yüzey tipi üzerinde elde ettiği doğruluk metrikleri.

Yüzey Tipi	Precision	Recall	F1-Score	IoU
Doğal	0.85	0.88	0.86	0.76
Restore edilmiş	0.92	0.93	0.93	0.86

Yahya ve diğ. [20], U-Net mimarisiyle beş farklı yığma taş duvar tipinde ortalama %82 F1-Score elde etmiş ve en yüksek başarı ise düzgün yontma taş duvar (aşklar fine) olarak tanımlanan duvar tipinde %97'lik F1-Score değeri ile gözlemlenmiştir. Buna karşılık, bu çalışmada ise doğal ve restore edilmiş yüzeylerden oluşan iki farklı yüzey tipinde, sırasıyla %86 ve %93 F1-Score elde

edilmiştir. Genel ortalama ise %90 olarak hesaplanmıştır. Benzer biçimde, Precision, Recall ve IoU gibi diğer değerlendirme metriklerinde de restore edilmiş yüzeylerde daha yüksek başarı gözlemlenmiştir. U-Net mimarisi DesNet-121 omurgası ile kullanılan başka bir çalışmada [17], doğrulama veri seti üzerinde sırasıyla %78 Precision, %80 Recall ve %78 F1-Score değerlerine ulaşılmıştır. Bu çalışmada ise doğal ve restore edilmiş taş yüzeylerinde sırasıyla %85-%92 Precision, %88-%93 Recall ve %86-%93 F1-Score değerlerine ulaşılmıştır. Elde edilen sonuçlar, önerilen yöntemin farklı yüzey tiplerinde rekabetçi bir performans sergilediğini ve benzer segmentasyon problemleri için uygulanabilir bir çözüm sunduğunu ortaya koymaktadır. Ayrıca, U-Net mimarisinin hem düzenli hem de düzensiz taş yüzeylerin segmentasyonu açısından yüksek doğruluk ve kararlılık sağladığı görülmektedir.



Şekil 4. Restore edilmiş yüzey tiplerine ait örnek görüntüler. (Sol sütunda İHA görüntüsü, orta sütunda referans maske görüntüsü, sağ sütunda ise modelin tahmin görüntüsü yer almaktadır.)

Restore edilmiş yüzeylere ait tahmin görüntüleri incelendiğinde, modelin yüksek kenar yakalama hassasiyetine sahip olduğu ve derz işlemleri gerçekleştirilmiş alanlarda taş kenar sürekliliği başarılı şekilde korunduğu görülmektedir. Taş geometrisinin tutarlılığının yanı sıra, içbükey ve dışbükey köşeler büyük oranda doğru temsil edilmiştir. Ayrıca, referans

maske görüntülerinde eksik olan birçok taş kenarı, model tahminlerinde kapanmıştır ve bu durum belgeleme çalışmaları açısından anlamlı katkılar sağlamıştır. Şekil 4'te restore edilmiş İHA görüntüleri, bunlara ait referans maske görüntülerini ve model tarafından üretilen tahmin görüntüleri karşılaştırmalı olarak sunulmuştur.


Restore edilmiş yüzeylerde model, restorasyon sonrası düzgün derz aralıkları ve açık renkli harç zemininde sağladığı taş-arka plan ayırım kolaylığından net bir biçimde yararlanabilmektedir. Özellikle köşe ve kırık hatların korunması dikkat çekicidir. Görselde kırmızı kutularla işaretlenen alanlarda, referans maske görüntüsünde yer almayan taş parçalarının model tarafından kapalı poligonlar halinde tamamlandığı görülmektedir. Bu bütünlük, yığma duvarlarda taş segmentasyonu açısından oldukça kritiktir.

A örneği incelendiğinde, üst kenara yakın dar bir taş ucunun bulunduğu görülmektedir. Referans maskede taşın uç kısmı eksik bırakılmıştır. Model tahmininde ise bu eksiklik giderilmiş ve taşın kenar hattı süreklilik kazanacak biçimde tamamlanmıştır. B örneğinde ise, sağ kenarda dar bir derz dolgusu ve küçük taşlarla çevrili bir taş gövdesi yer almaktadır. Referans maske görüntüsünde bu bölgedeki taşın dış hatları eksik bırakılmıştır. Tahmin görüntüsü incelendiğinde ise taş gövdesinin kapalı biçimde tamamlandığı görülmektedir. Model tahmini, taş-harç ayırımını korumuş ve bu sayede beklenen şekilde tek bir taş olarak segmentasyonu gerçekleştirilmiştir.

C örneği, diğerlerinden farklı olarak yanlış bir maskeleme içeren durumu temsil etmektedir. Model bu bölgede taş olmadığını değerlendirmiş ve tahmin görüntüsünde tamamen kaldırmıştır. D örneğinde, modelin düşük kontrastlı ya da homojen dokuya sahip taş parçalarını zaman zaman arka plan olarak yorumlama eğiliminde olduğu görülmektedir. Bu tür segmentasyon hatalarının, kenar tabanlı filtreleme veya çoklu spektral veri ile desteklenmiş bir segmentasyon yaklaşımı ile azaltılabileceği öngörülebilir.

Son olarak, E örneği ise taş yoğunluğu yüksek bir bölgeyi temsil etmektedir. Sol üstteki küçük bir taş parçası referans maskede atlanmış olmasına rağmen, model bu taşı kapalı ve boyutsal olarak tutarlı şekilde segmentasyonunu gerçekleştirmiştir. Görüntüdeki taş sayısının ve yoğunluğunun artmasına rağmen, model tahminlerinde taşların biçimsel ve boyutsal doğrulukları korunduğu gözlemlenmektedir. Ayrıca, modelin arka plan görüntüsünden düşük düzeyde etkilendiği dikkat çekicidir.

Doğal yüzeylere ait tahmin görüntüleri ise Şekil 5'te gösterilmiştir. Model, değişken doku ve aydınlatma koşullarına rağmen taş karakteristiklerini tutarlı şekilde ayırt edebilmiştir. Harç bölgelerine sızma eğilimi sınırlı kalmış ve aşırı taşma nadiren rastlanmıştır. Çok ince harç hatlarında yer yer birleşme veya kopma durumu gözlemlenebilse bile, bu hatalar geniş alanlara yayılmamıştır. Şekilde kırmızı kutularla işaretlenen bölgelerde, referans maskede eksik bırakılan taşların model tahmininde kapalı ve süreklilik gösteren poligonlara dönüştüğü görülmektedir. Bu durum, modelin taş iç dokusunu ve yerel kontrast farklarını etkili biçimde algılayabildiğini göstermektedir.



Şekil 5. Doğal yüzey tiplerine ait örnek görüntüler. (Sol sütunda İHA görüntüsü, orta sütunda referans maske görüntüsü, sağ sütunda ise modelin tahmin görüntüsü yer almaktadır.)

A örneğinde harç yüzeyi görece düzgündür ve taşlar, restore yüzeylere kıyasla daha büyük boyutludur. Model, tahmin görüntüsünde taş kenarlarını keskin biçimde tanımlamaktadır. Ayrıca, dışbükey köşelerde ise kenar sürekliliği korunmaktadır. Maskede eksik olan taş uçları, model tahmininde tamamlanmış ve taşın geometrik bütünlüğü sağlanmıştır. Gölge altında kalan dar derz hatlarında kısmi daralma gözlenirse de taş sınırları büyük ölçüde korunmuştur.

B örneği, düşük kontrastlı ve homojen aydınlatma koşullarında çekilmiştir. Bu durum, taş ile harç arasındaki ton farklarının azaltarak segmentasyon için zorlayıcı bir ortam sunmaktadır. Ancak model, bu sınırlı ayırım gücüne rağmen taş sınırlarını büyük ölçüde korumayı başarmıştır. Referans maskede yer almayan bir taş parçasının segmentasyonu model tahmininde kapalı ve bütüncül bir biçimde gerçekleştirilmiştir.

C örneğinde, yüzeyde belirgin küçük çukurlar ve aşınma izleri bulunmaktadır. Model, bu girintili bölgeleri harç yerine taşın bir parçası olarak tahmin etmiştir. Böylece, sınıf karışmasını azaltmış ve taş-harç sınırlarının daha net biçimde tanımlanmıştır. Ancak, çok ince harç damarlarının bazı bölgelerde kesintiler gözlemlenmektedir. Bu tür durumlarda, morfolojik düzeltme ya da watershed gibi sonrası işlem tekniklerinin kullanılması segmentasyon doğruluğunu artırabilir.

D örneğinde yüzey dokusu düzensizdir ve uzunlamasına yerleşimli taşlara sahiptir. Harç hatlarının bazı bölgelerde oldukça daralması, taşlar arasındaki sınırların belirginliğini azaltarak segmentasyonu zorlaştırmaktadır. Buna rağmen model, bu ince geçişlerde dahi taş-harç ayrımını büyük ölçüde korumayı başarmıştır. Model, referans maskede eksik bırakılmış taşı, tahminde kapalı bir taş segmenti olarak başarıyla tanımlanmıştır. Taşlar arasında sınırlı düzeyde birleşme eğilimi gözlemlense de bu durum yaygın bir hata biçimde ortaya çıkmamıştır.

E örneğinde, taş yoğunluğu oldukça yüksek ve küçük taş parçalarından oluşan karmaşık bir yüzey deseninden oluşmaktadır. Bu zorlu yapıya rağmen model, taşların biçimsel sürekliliğini koruyabilmeyi başarmıştır. Üst bölümdeki kırmızı kutuda, maskelenmemiş taş ögesinin model tarafından eksiksiz biçimde segment edildiği gözlemlenmektedir. Model eksik işaretlenmiş bölgeyi yalnızca doldurmakla kalmamış, aynı zamanda taşın doğal sınırlarına yakın bir formda yeniden tanımlamıştır. Ancak, oldukça ince harç çizgilerinde zaman zaman kopmalar meydana gelmiş ve sınır ayrımının güçleştiği alanlarda ek iyileştirme adımlarını gerekli kılmıştır.

Her iki görsel birlikte değerlendirildiğinde, modelin hem doğal hem de restorasyon görmüş yüzeylerde taşları kararlı ve tutarlı biçimde ayırt edebildiği görülmektedir. Kırmızı kutularla işaretlenen bölgelerde, referans maskede eksik bırakılan taş parçalarının model tahminlerinde kapalı ve süreklilik gösteren segmentler olarak üretildiği dikkat çekmektedir. Bu durum, modelin taşın iç dokusu ile yerel kontrast farklarını etkili şekilde kullanabildiğini göstermektedir.

Genel olarak model, yüksek kenar yakalama başarısı sergilemektedir. Taş-harç sınırlarında sızma ya da aşırı taşma eğilimi sınırlı düzeyde kalmakta, köşe ve kırık hatlar büyük ölçüde korunmaktadır. Taş geometrisi, farklı parça boyutlarında dahi tutarlılıkla sürdürülebilmekte ve arka plan dokusu, aydınlatma farkı ve derz kaplaması gibi değişkenler model performansı anlamlı ölçüde etkilememektedir.

Her iki yüzey türünde elde edilen bulgular, önerilen yaklaşımın farklı yüzey türleri arasında genellenebilir bir davranış sergilediğini ve taş ölçeğinde güvenilir bir belgeleme çıktıları sunduğunu ortaya koymaktadır. En belirgin hatalar, çok ince derz çizgileri ile yüksek yansıtıcılığa sahip parlak yüzeylerde gözlemlenen çizgisel incelmelerdir. Ancak bu tür etkilerin, morfolojik filtreleme ya da kenar tabanlı iyileştirme gibi tamamlayıcı bir sonrası işlem (post-processing) adımıyla büyük ölçüde giderilebileceği öngörülmektedir.

Nitekim Yahya ve diğ. [20] tarafından gerçekleştirilen bir çalışmada, Watershed algoritmasının uygulanması sonucunda, obje düzeyindeki F1-Score değerlerinde ortalama %4'lük bir artış elde edilmiştir. Bu tür bir sonrası işlem, özellikle eksik veya hatalı algılanan derz çizgileri nedeniyle oluşan komşu taşların yanlışlıkla birleştirilmesi sorununu engelleyerek segmentasyon doğruluğunu anlamlı biçimde artırmıştır. Bu bulgular, morfoloji tabanlı ya da benzer yapıdaki sonrası işlem tekniklerinin, derin öğrenme tabanlı maskeleme çıktılarında yapısal iyileştirmeyi etkin biçimde destekleyebileceğini göstermektedir.

4. Sonuçlar

Bu çalışmada, İHA görüntüleri ile U-Net tabanlı bir derin öğrenme mimarisinin entegrasyonu yoluyla, yığma taş duvarlardaki taşların otomatik segmentasyonu değerlendirilmiştir. Temel amaç, kültürel miras varlıklarının taş ölçeğinde güvenilir ve karşılaştırılabilir biçimde belgelenmesini sağlayarak koruma ve karar süreçlerine yeniden üretilebilir biçimde veri temelli katkılar sunmaktır.

Elde edilen bulgular, derin öğrenme modelinin yığma duvar belgelenmesine yönelik etkili ve ölçeklenebilir bir analiz aracı sunduğunu göstermektedir. İHA tabanlı veri toplama süreci ise, temassız ve hızlı veri temini olanağı sayesinde zorlu çevresel koşullarda dahi sürdürülebilir ve tekrarlanabilir iş akışlarını desteklemektedir.

U-Net modeli, doğal ve restorasyon görmüş yüzeylerde yüksek doğrulukla segmentasyon gerçekleştirmiştir. Özellikle, Precision, Recall ve F1-Score gibi metriklerde başarılı sonuçlar elde edilmiştir. Görsel analizler ise taş-harç sınırlarını yüksek hassasiyetle tanımladığını, taş geometrisini farklı boyutlarda dahi tutarlılıkla koruduğunu ve modelin arka plan karmaşıklığından sınırlı düzeyde etkilendiğini ortaya koymuştur. Referans maskelerde eksik bırakılan taşların model tahminlerinde tamamlanması, modelin taş-harç ayrımına ilişkin yerel görsel ipuçlarını başarıyla değerlendirdiğini göstermektedir. Bu bulgular, segmentasyon çıktılarının yalnızca istatistiksel doğruluk açısından değil, aynı zamanda yapısal bütünlük bakımından da güçlü olduğunu göstermektedir.

Bununla birlikte, derin öğrenme tabanlı segmentasyon yaklaşımlarının öne çıkan sınırlılıklarından başında, yüksek miktarda ve tutarlı biçimde oluşturulmuş maskeleme verisine olan bağımlılık gelmektedir. Özellikle taş birimlerinin ayrıntılı şekilde etiketlenmesini zorunlu kılan bu ön işleme süreci, yöntemin geniş ölçekli uygulamalara uyarlanmasını güçleştirmektedir. Bu çerçevede, taş çeşitliliğine duyarlı yarı otomatik ya da otomatik maskeleme stratejilerinin, aktif öğrenme ve veri artırma teknikleriyle birlikte değerlendirilmesi önem taşımaktadır. Bu tür yaklaşımlar, veri hazırlama sürecini daha verimli ve ölçeklenebilir kılmak yanı sıra, sınırlı veriyle öğrenmenin etkinliğini artırma potansiyeline de sahiptir. Ayrıca, segmentasyon doğruluğunu etkileyebilecek aydınlatma farkları ve yüzey yansımalarının etkisini azaltmak amacıyla multispektral görüntüleme olanaklarının araştırılması da bu süreci destekleyici bir adım olarak nitelendirilebilir. Bu sayede, yöntemin farklı taş türleri ve yüzey özelliklerinde test edilmesi, modelin sağlamlığını ve uygulama alanlarını genişletme potansiyelini gösterebilir. Bu kapsamda, görünür-ötesi bantlar gibi alternatif spektral kaynakların kullanılması, modelin farklı koşullara uygulanabilirliğini test etme imkanı sunabilir.

Sonuç olarak, İHA görüntüleriyle desteklenen derin öğrenme temelli bu yaklaşım, taş bazında belgeleme ihtiyacına yanıt verebilecek düzeyde güvenilir, uygulanabilir ve genişletilebilir bir çözüm olarak değerlendirilmektedir.

Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

Kaynakça

- Marangoz, A. M., & Özen, M. (2020). Tarihi Yerleşim Alanlarının Yersel Fotogrametrik Yöntem ile 3B Modellenmesi: Zeynel Bey Türbesi Örneği. *Türkiye Fotogrametri Dergisi*, 2(1), 1-6.
- Erdal, K., & Makineci, H. B. (2021). Documentation of Cultural Heritage with Backpack LiDAR Usage on Photogrammetric Purpose. *Türkiye Lidar Dergisi*, 3(1), 1-6. <https://doi.org/10.51946/melid.921032>
- Günen, M. A., Öztürk, K. F., & Aliyazıcıoğlu, Ş. (2025). Optimizing Visibility of Historical Structures Using mWDE: Insights from the Kromni Valley, Gümüşhane, Türkiye. *International Journal of Engineering and Geosciences*, 10(1), 107-126. <https://doi.org/10.26833/ijeg.1529351>
- Bozdoğan, Ö., Yaman, A., & Yılmaz, H. M. (2022). An analysis on the corrosion of a cultural heritage. *International Journal of Engineering and Geosciences*, 7(2), 112-127. <https://doi.org/10.26833/ijeg.891616>
- Alyılmaz, C., Alyılmaz, S., & Yakar, M. (2010). Measurement of petroglyphs (rock of arts) of Qobustan with close range photogrammetry. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(Part 5), 29-32.
- Forster, A., Valero, E., Bosché, F., Hyslop, E., & Wilson, L. (2024). Digital Toolkit to Assist the Interpretation of Traditional Masonry Construction. *International Journal of Architectural Heritage*, 18(5), 725-739. <https://doi.org/10.1080/15583058.2023.2182729>
- Yakar, M., & Doğan, Y. (2017). Mersin Silifke Mezgit Kale Anıt Mezarı Fotogrametrik Rölöve Alımı Ve Üç Boyutlu Modelleme Çalışması. *Geomatik*, 2(1), 11-17. <https://doi.org/10.29128/geomatik.296763>
- Loverdos, D., & Sarhosis, V. (2023). Geometrical digital twins of masonry structures for documentation and structural assessment using machine learning. *Engineering Structures*, 275, 115256. <https://doi.org/10.1016/j.engstruct.2022.115256>
- Karataş, L. (2023). Yersel lazer tarama yöntemi ve ortofotoların kullanımı ile kültür varlıklarının cephelelerindeki malzeme bozulmalarının dokümantasyonu: Mardin Mungan Konağı örneği. *Geomatik*, 8(2), 152-162. <https://doi.org/10.29128/geomatik.1147639>
- Wang, T., Zhang, J., Chen, W., Chun, Q., & Sun, J. (2025). Pixel-level segmentation of spalling in masonry structures based on deep learning. *Engineering Structures*, 340, 120686. <https://doi.org/10.1007/s13349-024-00904-8>
- Zhang, J., Qiu, H., & Sun, J. (2025). Automatic detection of mortar loss on masonry building facades based on deep learning. *Journal of Civil Structural Health Monitoring*, 1-12. <https://doi.org/10.1016/j.engstruct.2025.120686>
- Kasem Agha, K., & Uzun, C. (2025). Point Cloud Semantic Segmentation of Building Elements of Fatih Mosque, Istanbul. *Journal of Architectural Sciences and Applications*, 10(1), 30-54. <https://doi.org/10.30785/mbud.1586902>
- Fornaciari, L. (2025). AI and Deep Learning for Image-Based Segmentation of Ancient Masonry: A Digital Methodology for Mensiochronology of Roman Brick. *Heritage*, 8(7). <https://doi.org/10.3390/heritage8070241>
- Oses, N., & Dornaika, F. (2013). Image-Based Delineation of Built Heritage Masonry for Automatic Classification. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7950 LNCS, 782-789. https://doi.org/10.1007/978-3-642-39094-4_90
- Oses, N., Dornaika, F., & Moujahid, A. (2014). Image-Based Delineation and Classification of Built Heritage Masonry. *Remote Sensing*, 6(3), 1863-1889. <https://doi.org/10.3390/rs6031863>
- Valero, E., Forster, A., Bosché, F., Hyslop, E., Wilson, L., & Turmel, A. (2019). Automated defect detection and classification in ashlar masonry walls using machine learning. *Automation in Construction*, 106, 102846. <https://doi.org/10.1016/j.autcon.2019.102846>
- Loverdos, D., & Sarhosis, V. (2022). Automatic image-based brick segmentation and crack detection of masonry walls using machine learning. *Automation in Construction*, 140, 104389. <https://doi.org/10.1016/j.autcon.2022.104389>
- Dreier, A., Tobies, A., Kuhlmann, H., & Klingbeil, L. (2025). Stone instance segmentation of rubble masonry based on laser scanning point clouds. *Measurement*, 242, 115905. <https://doi.org/10.1016/j.measurement.2024.115905>
- Ibrahim Yahya and Nagy, B. and B. C. (2019). CNN-Based Watershed Marker Extraction for Brick Segmentation in Masonry Walls. İçinde A. and Y. A. Karray Fakhri and Campilho (Ed.), *Image Analysis and Recognition* (ss. 332-344). Cham: Springer International Publishing.
- Yu, R., Li, P., Shan, J., & Zhu, H. (2022). Structural state estimation of earthquake-damaged building structures by using UAV photogrammetry and point cloud segmentation. *Measurement*, 202, 111858. <https://doi.org/10.1016/j.measurement.2022.111858>

21. Rocha, J. H. A., Gonzales, R. J. R., Castro, N. C. R., Rosas, M. H., Campos, A. A., Chileno, N. G. C., & Lordsleem Júnior, A. C. (2025). The Utilization of Unmanned Aerial Vehicles (UAVs) in Cultural Heritage Buildings: A Systematic Literature Review. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 49(3), 2241-2256. <https://doi.org/10.1007/s40996-024-01523-5>
22. Alyılmaz, C., Yakar, M. & Yılmaz, H. M. (2010). Drawing of petroglyphs in Mongolia By Close Range Photogrammetry. *Scientific-Research and Essays*, 5(11), 1216-1222.
23. Polat, Y., & Tamsü Polat, R. (2025). Arkeolojik Belgelemede Teknolojik Yaklaşımlar: Yazılıkaya/Midas Kale Çalışmaları. *Geomatik*, 10(3), 364-374. <https://doi.org/10.29128/geomatik.1643529>
24. Öztürk, O., Bilgilioğlu, B. B., Çelik, M. F., Bilgilioğlu, S. S., & Uluğ, R. (2017). İnsan Hava Aracı (İHA) Görüntüleri İle Ortofoto Üretiminde Yükseklik Ve Kamera Açısının Doğruluğa Etkisinin Araştırılması. *Geomatik*, 2(3), 135-142. <https://doi.org/10.29128/geomatik.327049>
25. Yakar, M. (2011). Using close range photogrammetry to measure the position of inaccessible geological features. *Experimental Techniques*, 35(1), 54-59.. <https://doi.org/10.26833/ijeg.1487818>
26. Özdemir, E., Çallı, R., & Kartal, S. (2024). Utilization of unmanned aerial vehicles for the detection and localization of deteriorations in historical structures: a case study of Ishak Pasha Palace. *International Journal of Engineering and Geosciences*, 9(3), 377-389. <https://doi.org/10.26833/ijeg.1464867>
27. Yakar, M., Yılmaz, H. M., & Yurt, K. (2010). The effect of grid resolution in defining terrain surface. *Experimental Techniques*, 34(6), 23-29.. <https://doi.org/10.53093/mephoj.1198605>
28. Rize İl Kültür ve Turizm Müdürlüğü. (t.y.). Zil Kale. Erişim tarihi: 26 Eylül 2025, <https://rize.ktb.gov.tr/TR-347095/zil-kale.html>
29. Ibrahim, Y., Szulovszky, P., & Benedek, C. (2023). Masonry Structure Analysis, Completion and Style Transfer Using a Deep Neural Network (ss. 155-168). https://doi.org/10.1007/978-3-031-37731-0_13
30. Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. *In International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Cham: Springer international publishing.
31. Pavel Iakubovskii. (2019). Segmentation Models Pytorch. *GitHub repository*. https://github.com/qubvel/segmentation_models.pytorch
32. Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. *İçinde 2009 IEEE Conference on Computer Vision and Pattern Recognition* (ss. 248-255). IEEE. <https://doi.org/10.1109/CVPR.2009.5206848>
33. Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019, July). Optuna: A next-generation hyperparameter optimization framework. *In Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 2623-2631).



© Author(s) 2026. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>