

Beton Yüzey Çatlaklarının YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi

Muhammet Gökhan ALTUN^{1,a}, Ahmet Hakan ALTUN^{2,b}

¹Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Çanakkale

²Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Bursa

^aORCID: 0000-0002-9345-9907; ^bORCID: 0009-0001-7142-0470

Makale Bilgileri

Geliş : 23.07.2024

Kabul : 27.09.2024

DOI: 10.21605/cukurovaumfd.1560104

Sorumlu Yazar

Muhammet Gökhan ALTUN

muhammetgokhan.altun@comu.edu.tr

Anahtar Kelimeler

Beton

Çatlak tespiti

Görüntü işleme

Atf şekli: ALTUN, M.G., ALTUN, A.H., (2024). Beton Yüzey Çatlaklarının YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(3), 667-678.

ÖZ

Beton kullanım ömrü boyunca takip edilmeli, varsa hasarlar tespit edilmeli ve gerekli işlemler zamanında yapılmalıdır. Bundan dolayı doğru zamanda doğru tespit betonun dayanıklılığı açısından oldukça önemlidir. Çatlaklar, betonarme yapıların zarar gördüğünün en erken sinyalleridir. Türkiye gibi deprem riski yüksek bölgelerde yapıların dayanıklılığı ve güvenliği açısından çatlakların erken tespiti hayati öneme sahiptir. Çatlakları manuel olarak tespit etmek genellikle zaman, işgücü, maliyet, yüksek hata olasılığı ve uygulamadaki zorluklar açısından oldukça dezavantajlıdır. Manuel tespite alternatif olarak görüntü işleme teknikleri, makine öğrenmesi ve derin öğrenme tabanlı algoritmaların bu alanda kullanımı yaygınlaşmaktadır. Bu çalışmada, Orta Doğu Teknik Üniversitesi kampüsündeki farklı binalardan elde edilen görüntülerden oluşan METU veri kümesi kullanılarak beton yüzeyindeki çatlakların görüntü işleme yöntemi ile tespit edilmesi amaçlanmıştır. Veri kümesinden 550 adet örnek görüntü seçilmiş olup bu görüntülerin 500 adedi pozitif, kalan 50 adedi ise negatif görüntüden oluşmaktadır. Veri seti çeşitli veri artırma teknikleri ile 1330 örneğe genişletilmiştir. Veri seti %88 eğitim, %8 doğrulama, %4 test kümesi olarak bölünmüştür. Sonuç olarak 1170 adet görüntü eğitim, 105 adet görüntü doğrulama ve 55 adet görüntü ise test için kullanılmıştır. Eğitim işlemi Google Colab ortamında gerçekleştirilmiştir. Model olarak YOLO serisinden YOLOv8 modeli kullanılmıştır. Elde edilen sonuçlara göre modelin çatlak tahminlerinde çok az yanlış pozitif sonuç verdiği ve farklı sınıfları ayırt etmede yüksek başarı gösterdiği tespit edilmiştir.

Concrete Surface Crack Detection via YOLOv8 Deep Learning Algorithm

Article Info

Received : 23.07.2024

Accepted : 27.09.2024

DOI: 10.21605/cukurovaumfd.1560104

Corresponding Author

Muhammet Gökhan ALTUN

muhammetgokhan.altun@comu.edu.tr

Keywords

Concrete

Crack detection

Image processing

How to cite: ALTUN, M.G., ALTUN, A.H., (2024). Beton Yüzey Çatlaklarının YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(3), 667-678.

ABSTRACT

Concrete should be monitored throughout its service life, any damages should be detected, and necessary repairs should be promptly carried out. Therefore timely and accurate detection is crucial for the durability of concrete. Cracks are the earliest indicators of damage in reinforced concrete structures. Especially in high seismic risk regions like Turkey, early detection of cracks is of vital importance for the resilience and safety of structures. Manual detection of cracks is generally disadvantaged in terms of time, labor, cost, high error probability, and application difficulties. As an alternative to manual inspection, image processing techniques and algorithms based on machine learning and deep learning are increasingly being utilized in this field. This study aims to detect cracks on concrete surfaces using image processing methods with the METU dataset consisting of images from various buildings on the Middle East Technical University campus. A total of 550 sample images were selected from the dataset, comprising 500 positive and 50 negative images. The dataset was expanded to 1330 examples using various data augmentation techniques. The dataset was divided into 88% training, 8% validation, and 4% test sets. Thus 1170 images were used for training, 105 for validation, and 55 for testing. The training process was conducted in the Google Colab environment using the YOLOv8 model from the YOLO series. According to the results obtained, the model produced very few false positive results in crack predictions and demonstrated high accuracy in distinguishing different classes.

1. GİRİŞ

Beton günümüzde en çok kullanılan yapı malzemelerinden biridir. Yapıların dayanıklılığı, sağlamlığı ve ömrü betonun kalitesine ve iç yapısına bağlıdır. Yapı hizmet ömrü boyunca, değişen yükleme koşulları, korozyon, donma çözülme, klor difüzyonu, karbonatlaşma, biyolojik oluşumlar gibi çeşitli mekanik, fiziksel ve kimyasal etkilere maruz kalmaktadır. Bu etkiler betonun çatlamasına ve bozulmasına sebep olmaktadır. Bu bozulmalar, önlem alınmadığı takdirde, yapıların yapısal bütünlüğünü tehlikeye atmanın yanı sıra önemli insan ve mali kayıplara sebep olabilir [1-6]. Çatlaklar, betonarme yapıların zarar gördüğünün en erken sinyalleridir. Türkiye gibi deprem riski yüksek bölgelerde yapıların dayanıklılığı ve güvenliği açısından çatlakların erken tespiti hayati öneme sahiptir. Hizmet ömrü boyunca yapının performansı ve güvenliğini sağlamak için çatlakların tespit edilmesi, derinliğinin ve miktarının belirlenmesi doğru teşhisin konulması açısından oldukça önemlidir [7]. Çatlakları manuel olarak tespit etmek genellikle zaman, işgücü, maliyet, yüksek hata olasılığı ve uygulamadaki zorluklar açısından oldukça dezavantajlıdır. Son yıllarda manuel tespiti alternatif olarak görüntü işleme teknikleri, makine öğrenmesi ve derin öğrenme tabanlı algoritmaların bu alanda kullanımına yönelik araştırmaların yaygınlaştığı literatürden anlaşılmaktadır [8,9].

Rimkus ve arkadaşları (2015) tarafından yapılan çalışmada, beton yapıların sıkça karşılaştığı çatlak sorunlarını çözmek için dijital görüntü analiz sistemlerinin kullanımı önerilmiştir. Geleneksel yöntemlerin aksine dijital görüntü korelasyon teknolojisinin çatlakların yerini etkin bir şekilde belirlemede avantaj sağladığı ifade edilmiştir. Çalışmada görüntü işleme sürecinin iki aşamalı olduğu ve çatlakların dikey konumlarının tespitinde kullanıldığı belirtilmiştir. Çatlak piksellerinin tanımlanmasında hiyerarşik kümelendirme tekniği'nin kullanıldığı ve bu yöntemin etkinliğinin deneysel verilerle desteklendiği açıklanmıştır [7].

Ni ve arkadaşları (2020) tarafından yapılan çalışmada çatlak tespiti yapabilen akıllı telefon uygulaması geliştirilmiştir. Akıllı telefon zoom lensi ile beton çatlaklarının doğru tespit edilebileceği ifade edilmiştir. Kamera haricinde lazer tarama ve görüntü işlemenin birlikte kullanımı da giderek yaygınlaşmaktadır [10].

Miao ve Srimahachota (2021) tarafından yapılan çalışmada, beton yüzey çatlaklarını tespit etmek ve niceliklerini belirlemek için yarı otomatik bir sistem geliştirilmiştir. Çalışmada dört yaygın evrişimli sinir ağı (CNN) modeli test edilmiş ve GoogLeNet'in transfer öğrenme ile eğitilmiş versiyonunun iki farklı veri setinde dengeli performans sergilediği belirtilmiştir. Ayrıca "mahalle taraması" adı verilen yeni bir teknik önerilmiş ve önceki çift tarama yöntemi ile benzer performans gösterdiği tespit edilmiştir. Önerilen çatlak genişliği hesaplama yöntemi önceki yöntemlere kıyasla daha düşük ortalama göreceli hata sunmaktadır [9].

Rucka ve arkadaşları (2021) tarafından yapılan çalışmada, dijital görüntü işleme tekniği ve ultrasonik test birlikte uygulanarak poliolefin lif takviyeli beton kirişlerdeki hasarın gelişimi karakterize edilmiştir. Çalışma sonuçlarına göre, önerilen yöntemin kırılma sürecinin gerçek zamanlı izlenmesi için, bir sistemde otonom hasar göstergeleri olarak kullanılabilmesi yazarlar tarafından bildirilmiştir [11].

Sevinç ve Özyurt (2022) tarafından yapılan çalışmada, Orta Doğu Teknik Üniversitesi kampüs binalarından toplanan veri seti kullanılarak derin öğrenme modelleri aracılığıyla beton yüzey çatlaklarının tespit edilmesi amaçlanmıştır. Bu kapsamda görüntüler ResNet-50, VGG-16, Inception-V3, Xception derin CNN mimarileri ve MobileNet, ShuffleNet, EfficientNet hafif CNN mimarilerini kullanarak eğitilmiştir. Sonuçlar karşılaştırıldığında elde edilen doğruluk oranlarının başarılı ve birbirine yakın olduğu tespit edilmiştir [12].

Vivekananthan ve arkadaşları (2023) tarafından yapılan çalışmada, beton köprüdeki çatlakların tespiti için geliştirilmiş OTSU yöntemi kullanılmıştır. Yöntem görüntü ön işleminde gri seviye ayrımı yaklaşımını kullanarak çatlakların tespit edilme doğruluğunu arttırmayı hedeflemektedir. Çatlakların kenar piksellerini belirlemek için Sobel filtresi kullanılmıştır. Sonuç olarak çalışmada kullanılan bu yöntemin beton köprü çatlaklarını %95'e varan bir doğruluk oranıyla tespit ettiği ifade edilmiştir [13].

Iraniparast ve arkadaşları (2023) tarafından yapılan çalışmada, beton yüzeylerdeki çatlakların tespiti ve segmentasyonu için transfer öğrenme ve çok çözünürlüklü görüntü işleme teknikleri kullanılmıştır. Çatlak segmentasyonunda dalga dönüşümüne dayalı çok çözünürlüklü görüntü analizi uygulanmıştır. Derin evrişimli sinir ağları (DCNN) ve transfer öğrenme yöntemleri beton yüzey çatlakların tespiti için kullanılmıştır. DCNN sınıflandırıcı modellerin yüksek performans gösterdiği ve önerilen çok çözünürlüklü görüntü analizinin çatlak piksellerini %95,25 F1 skoru ile segmentleyebildiği belirlenmiştir [14].

Beton, doğru uygulama ve zamanında gerekli bakım ve onarım yapıldığında oldukça uzun ömürlü bir malzemedir. Beton kullanım ömrü boyunca takip edilmeli, varsa hasarlar tespit edilmeli ve gerekli işlemler zamanında yapılmalıdır. Bundan dolayı doğru zamanda doğru tespit betonun dayanıklılığı açısından oldukça önemlidir [15-17]. Yapının kullanım ömrü boyunca geleneksel ve manuel olarak takip edilmesi ve değerlendirilmesi süreci işgücü ve zaman açısından düşünüldüğünde yavaş ve maliyetlidir. Ayrıca kişinin bilgisine, becerisine ve tecrübesine bağlı olduğundan yeterince objektif değildir. Son yıllarda yapılan çalışmalar görüntü işleme ve makine öğrenmesi modellerinin yapısal sağlık izleme de tahribatsız metot olarak kullanılabilceğini göstermektedir [17,18]. Konu ile ilgili çalışmalar sınırlı sayıda olup farklı makine öğrenmesi ve derin öğrenme algoritmalarının kullanıldığı çok daha fazla araştırmaya ihtiyaç bulunmaktadır. Bu çalışmada, çatlakları daha hızlı ve daha doğru tespit etmek amacıyla METU veri seti üzerinde Yolov8 derin öğrenme algoritması kullanılmış ve literatürde yapılan diğer çalışmalarla kıyaslanmıştır.

2. METODOLOJİ

2.1. Veri Seti


Bu çalışmada, Orta Doğu Teknik Üniversitesi kampüsündeki farklı binalardan elde edilen toplam 40.000 adet görüntü içeren METU veri kümesi kullanılmıştır. Veri kümesinin 20.000 adedi pozitif yani çatlak içeren görüntülerden, 20.000 adedi ise negatif yani çatlak içermeyen görüntülerden oluşmaktadır [19]. Bu çalışma için veri kümesinden 550 adet örnek görüntü seçilmiş olup bu görüntülerin 500 adedi pozitif, kalan 50 adedi ise negatif görüntüden (background) oluşmaktadır. Veri seti Roboflow sitesi üzerinden anotasyonlanmış ve çeşitli veri artırma teknikleri (dikey ve yatay döndürme, bulanıklık ekleme, gürültü ekleme, doyma, belirli açıda döndürme gibi) uygulanarak 1330 örneğe genişletilmiştir. Veri seti %88 eğitim, %8 doğrulama, %4 test kümesi olarak bölünmüştür. Sonuç olarak 1170 adet görüntü eğitim, 105 adet görüntü doğrulama ve 55 adet görüntü ise test için kullanılmıştır.

Çatlak içeren görüntüler pozitif, background olan görüntüler ise null olarak etiketlenmiştir. Null, Roboflow etiketlemesinde background olarak temsil edilmektedir [20]. Görüntü boyutları YOLO için 256x256 piksel olarak sabitlenmiş ve piksel değerleri 0 ile 1 arasında normalize edilmiştir. Çalışma kapsamında kullanılan veri seti içerisinde yer alan bazı görüntüler Şekil 1'de gösterilmiştir.

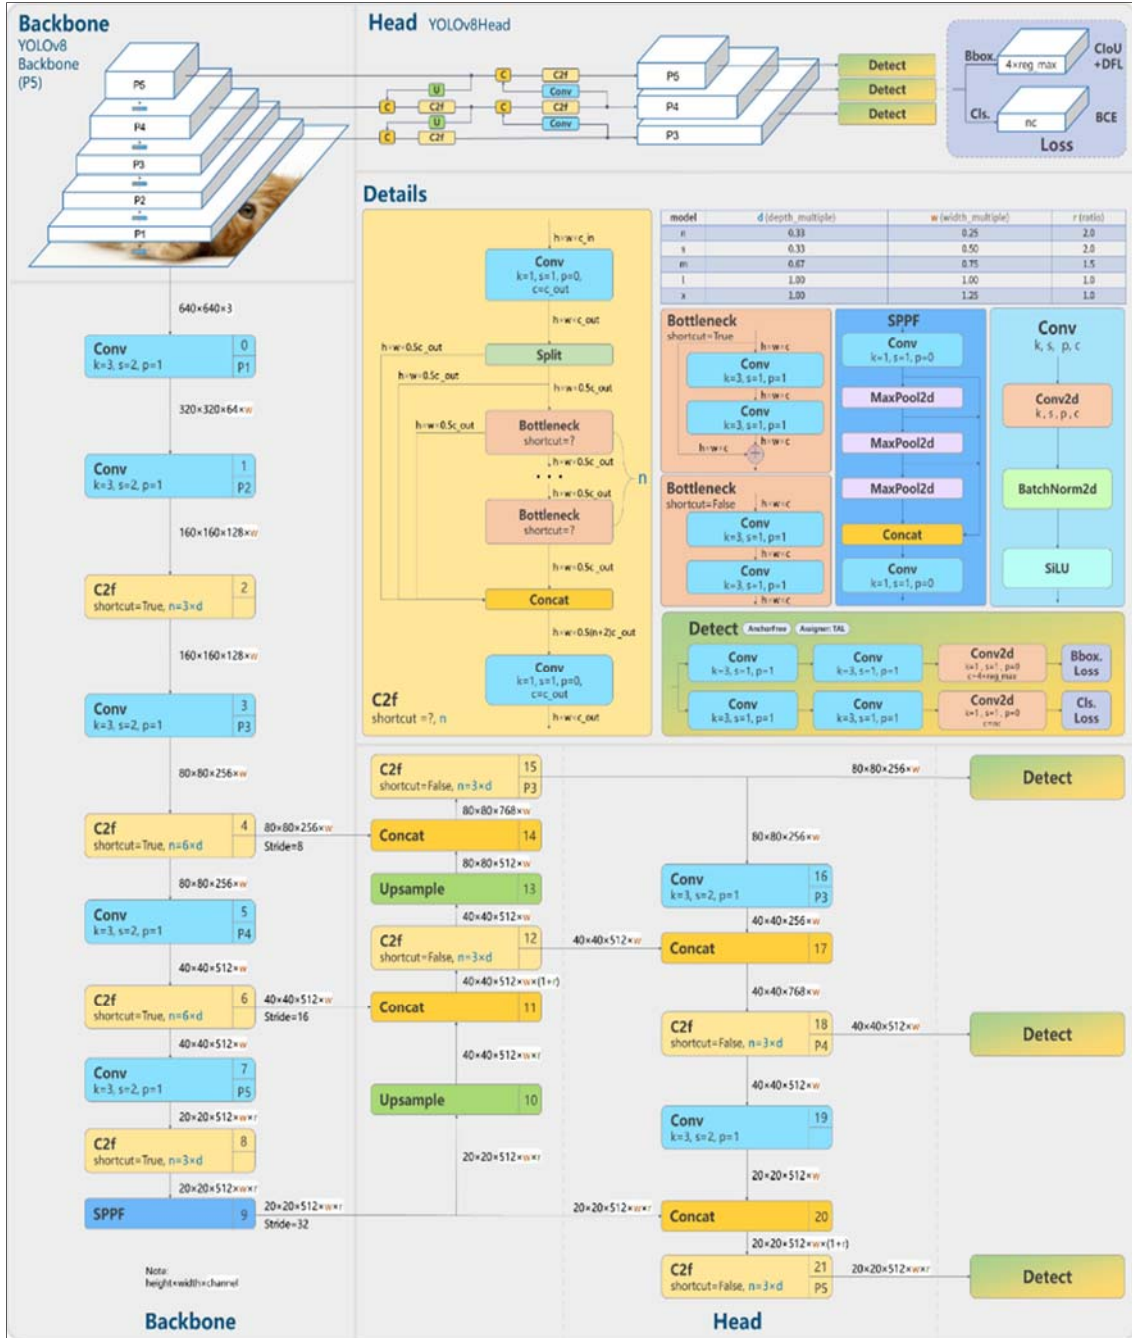
2.2. Yöntem

Eğitim işlemi Google Colab ortamında gerçekleştirilmiştir. Google Colab, tarayıcı üzerinden erişilebilen bulut tabanlı bir Jupyter not defteri hizmetidir. Intel CPU'larla donatılmış olup yaklaşık 12 GB RAM kapasitesine sahiptir. Ayrıca derin öğrenme gibi hesaplama yoğun işlemler için NVIDIA Tesla T4, A100, L4 ve TPU v2-8 gibi GPU ve TPU'lardan birini seçme imkanı sunmaktadır. Bu çalışmada NVIDIA Tesla T4 GPU kullanılmıştır [21].

Model olarak YOLO serisinden YOLOv8 modeli kullanılmıştır. YOLOv8' de yapılan mimari iyileştirmeler, daha derin ve etkili özellik temsilleri sağlamak üzere 3x3 filtrelerin tercih edilmesi gibi değişiklikleri içermektedir. Ayrıca, modelin ana yapı bloğu (C2f, C3) yeniden tasarlanmış ve aktivasyon fonksiyonu olarak SiLU kullanılmıştır. YOLOv8 veri artırımı teknikleriyle eğitim sırasında görüntülerin çeşitli varyasyonlarını işleyerek genellemeyi artırmayı hedeflemektedir. YOLOv8 COCO veri setinde yapılan testlerde yüksek doğruluk göstermiş ve Roboflow 100 benchmark da diğer popüler modellere göre üstün performans sergilemiştir [22]. Şekil 2'de YOLOv8'in mimarisi detaylı olarak gösterilmiştir [22,23]



Şekil 1. Veri setine ait örnek görüntüler



Şekil 2. YOLOv8'in mimarisi [22,23]

2.3. Değerlendirme Metrikleri

Veri seti, YOLOv8'in önceden eğitilmiş ağırlıkları üzerinde 100, 200 ve 300 dönemler boyunca eğitilmiştir. Eğitim sürecinde modelin kaybı (loss) ve doğruluğu (accuracy) gibi performans metrikleri düzenli olarak kaydedilmiş ve incelenmiştir. En iyi sonuçları elde etmek için eğitim parametreleri dikkatlice ayarlanmış ve test edilmiştir. Eğitim sürecinde kullanılan metrikler modelin doğruluğunu ve genel performansını belirlemek için kritik öneme sahiptir. Kaydedilen sonuçlar daha sonra doğruluk, duyarlılık, pozitif tahmin değeri, negatif tahmin değeri, F1 değeri, karmaşıklık matrisi gibi değerlendirme ölçütleri üzerinden incelenmiştir.

Bu ölçütler gerçek pozitif (TP), yanlış pozitif (FP), gerçek negatif (TN) ve yanlış negatif (FN) olmak üzere dört kategori üzerinden hesaplanmaktadır ve modelin performansı açısından önemli bilgiler sunmaktadır. Doğruluk (accuracy) modelin doğru tahminlerinin genel veri seti içerisindeki oranını göstermektedir. Duyarlılık (recall) gerçek pozitiflerin doğru sınıflandırılma oranını ifade etmektedir. F1 değeri, doğruluk ve duyarlılık metriklerinin harmonik ortalaması olarak hesaplanmaktadır. Pozitif tahmin değeri modelin pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma oranını göstermektedir. Negatif tahmin değeri ise modelin negatif olarak tahmin ettiği örneklerin gerçekten negatif olma oranını ifade etmektedir [24]. Söz konusu metrikler Eşitlik (1-5) yardımıyla hesaplanmaktadır.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FN} + \text{TN} + \text{FP}) \quad (1)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (2)$$

$$\text{F1 score} = 2\text{TP} / (2\text{TP} + \text{FP} + \text{FN}) \quad (3)$$

$$\text{Positive predictive value} = \text{TP} / (\text{TP} + \text{FP}) \quad (4)$$

$$\text{Negative predictive value} = \text{TN} / (\text{TN} + \text{FN}) \quad (5)$$

3. ANALİZ SONUÇLARI


Bu çalışma, beton çatlaklarının tespiti için YOLOv8 modeli kullanılarak gerçekleştirilmiştir. Eğitim süreci METU'dan elde edilen 1170 görüntü üzerinde NVIDIA Tesla T4 TPU kullanılarak gerçekleştirilmiştir. Modelin performansını değerlendirmek için farklı eğitim dönemlerinde elde edilen değerlendirme metrikleri kullanılmıştır. Eğitim sürecinin farklı dönemlerinden elde edilen MAP (Mean Average Precision) değerleri, değerlendirme metrikleri ve zaman değerleri Çizelge 1'de verilmiştir. MAP değerleri göz önüne alındığında en iyi sonucu 200. dönemin, doğruluk açısından en iyi sonucu 300. dönemin, duyarlılık açısından en iyi sonucu 100. dönemin, F1 skoru olarak 100. ve 200. dönemlerin en yüksek sonucu verdiği tespit edilmiştir. Tüm bu metrikler ve zaman açısından değerlendirildiğinde 200. dönemin genel olarak daha iyi sonuç verdiği belirlenmiş ve model 200 eğitim dönemi baz alınarak eğitilmiş ve sonuçlar bu bağlamda değerlendirilmiştir.

Çizelge 1. Farklı eğitim dönemlerinden elde edilen sonuçlar

Eğitim Dönemi	MAP@50	MAP@50-95	Doğruluk	Duyarlılık	F1 değeri	Zaman (saat)
100	0,965	0,841	0,958	0,934	0,95	0,350
200	0,971	0,855	0,959	0,933	0,95	0,645
300	0,970	0,859	0,964	0,894	0,93	0,970

Bunun nedeni, modelin 200. döneme kadar öğrenme sürecinde uygun bir denge yakalaması yani hem eğitim verileri üzerinde yeterli öğrenmeyi gerçekleştirmesi hem de aşırı uyuma (overfitting) eğilimini minimize etmesidir. Eğitim sürecini daha da arttırmak modelin eğitim verisine daha fazla uyum sağlamasına dolayısıyla ezberleme eğilimine yol açabilmektedir.. Bu modelin genel performansını ve gerçek dünya verileri üzerindeki genelleme yeteneğini olumsuz etkileyebilmektedir. Eğitim sürecinin artırılması her zaman daha iyi güvenlik veya performans sağlamaz, bu yüzden hiperparametre ayarlamaları ve erken durdurma (early stopping) gibi stratejiler kullanılarak optimal eğitim süresi belirlenmelidir [25-27]. Modelin performansının kötü gittiğinden emin olmak için 300. döneme kadar testler yapılmıştır.


Şekil 3'de modelin karmaşıklık matrisi verilmiştir. Karmaşıklık matrisi modelin başarısını doğru şekilde ölçmek ve değerlendirmek için oldukça önemlidir. Bu matris yardımıyla farklı performans metriklerinin değerleri belirlenmekte ve böylece modelde iyileştirmeler yapmak ve gerçeğe en yakın tahminler üretebilmek mümkün olabilmektedir [24]. Buna göre modelin doğru bir şekilde çatlak olarak tespit ettiği örnek sayısı yani doğru pozitif değeri 115'tir. Çatlak olmayan alanları yanlışlıkla çatlak olarak sınıflandırdığı örnek sayısı yani yanlış pozitif sayısı 15'dir. Modelin tespit edemediği gerçek çatlak sayısı yani doğru negatif sayısı ise 5'tir. Modelin yüksek gerçek pozitif değeri çatlakları etkin bir şekilde tespit edebildiğini göstermektedir.




Şekil 3. Karmaşıklık matrisi

Modelin doğruluk-duyarlılık (P-R) eğrisi Şekil 4'te gösterilmiştir. Eğriye göre model pozitif olarak etiketlenen çatlakları %96,9 oranında kesinlikle doğru bir şekilde tespit etmektedir. Tüm sınıflar için ortalama kesinlik (MAP) değeri de %96,9 olarak belirlenmiştir. Bu sonuçlar modelin çatlak tahminlerinde çok az yanlış pozitif sonuç verdiğini ve farklı sınıfları ayırt etmede yüksek başarı gösterdiğini ifade etmektedir. Modelin yüksek kesinlik puanı gerçek pozitifleri (çatlakları) tespit etmede güvenilir olduğunu göstermektedir.

Modelin F1 skoru Şekil 5'de gösterilmiştir. En yüksek F1 skoru yaklaşık 0,626 güven eşik değerinde 0,93'tür. Güven eşik değeri 0,8 civarında iken F1 skoru azalmaya başlamakta ve 1,0'e yaklaştıkça keskin bir azalma görülmüştür. Bunlara göre model belirtilen güven eşik değerinde en iyi dengeli doğruluk ve hatırlama oranına sahiptir ancak yüksek güven eşiklerinde yanlış negatifleri artırabileceğine işaret etmektedir. Çeşitli düzenleme teknikleri (Dropout, L2 düzenleme), veri çeşitlendirme ve artırma, erken durdurma (early stopping) ve çapraz doğrulama gibi yöntemler ile modelin aşırı uyuma eğilimi azaltılarak, genelleme yeteneği ve güvenilirliği artırılarak performansı iyileştirilebilmektedir [25-27].




Şekil 4. Doğruluk-duyarlılık (P-R) eğrisi

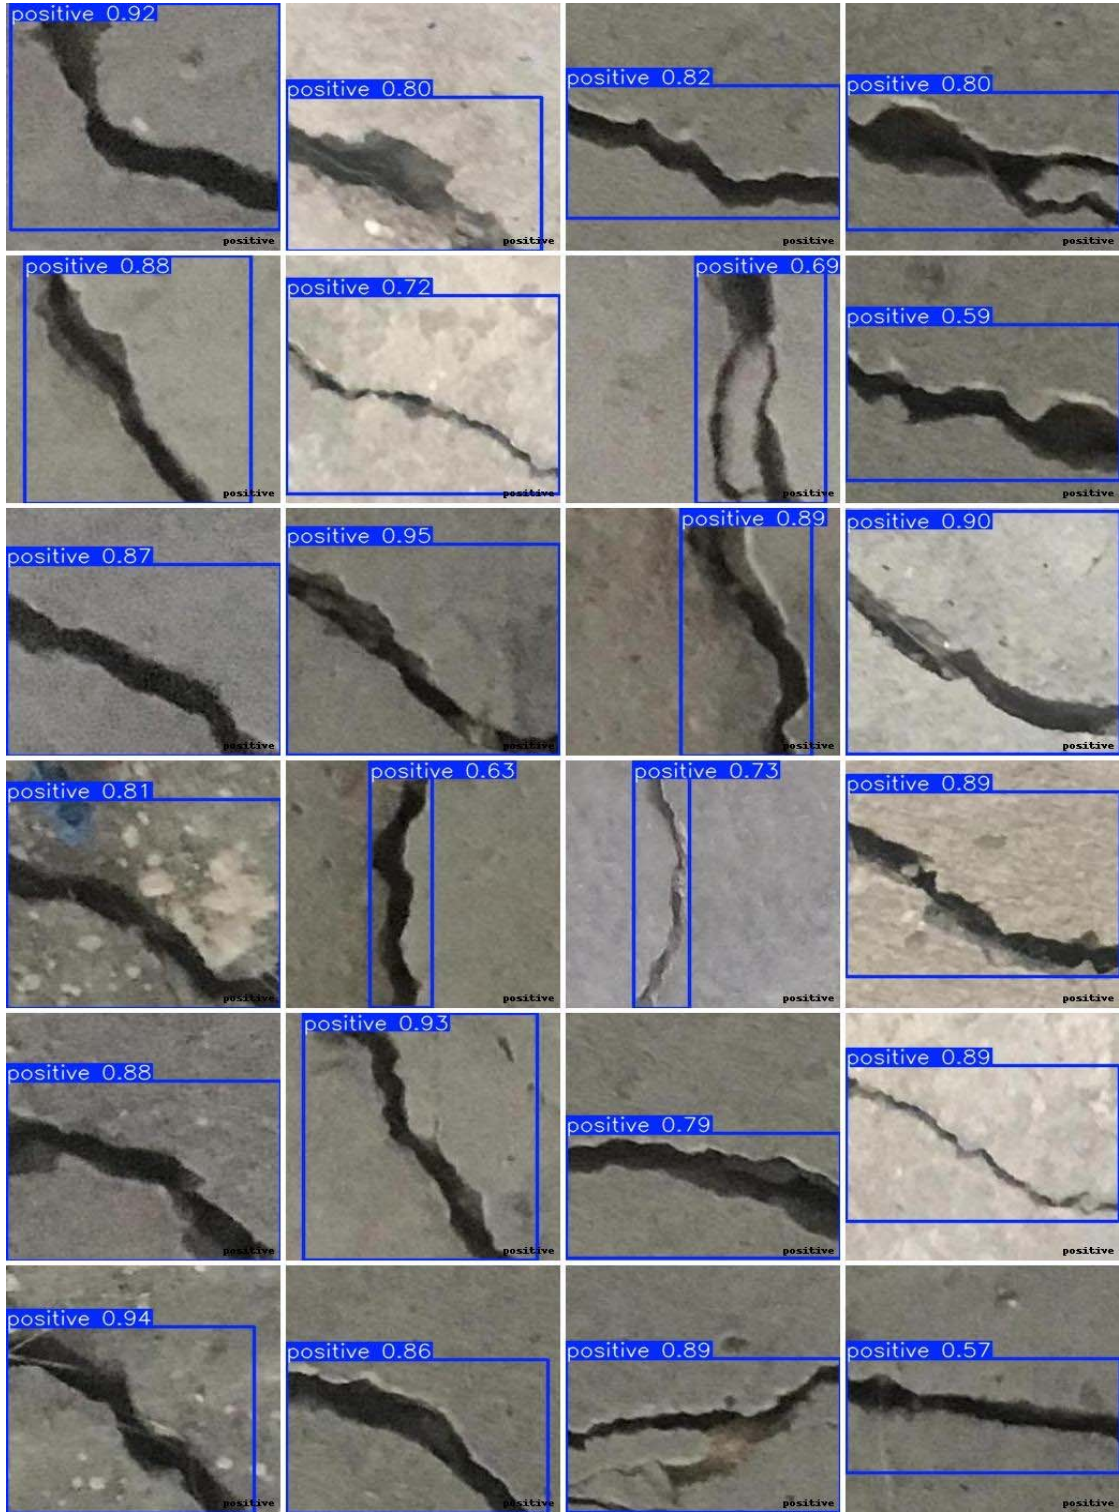


Şekil 5. F1 güvenilirlik eğrisi

Modelin eğitim sonuç grafikleri Şekil 6’da, modelin tahmin örnekleri Şekil 7’de verilmiştir. Bu grafiklere göre eğitim kayıplarında azalma görülmektedir. Bu modelin zamanla daha iyi öğrendiğini ve performansının arttığını göstermektedir. Eğitim süresi boyunca modelin performansı belirli aralıklarla test edilmekte ve genellikle öğrenme eğrileri kullanılarak analiz edilmektedir. Düşük dönem sayısı ile modelin veri setini tam öğrenememesi yani eksik öğrenme ve modelin performansının yetersiz olması anlamına gelmektedir. Yüksek dönem sayısı ise aşırı uyuma neden olabilmekte yani model eğitim verisine fazla uyum sağlayıp genelleme yeteneğini kaybedebilmektedir. Bu nedenle ideal eğitim süresi genellikle performans metriğinin en yüksek olduğu döneme göre belirlenmektedir [25-27]. Doğruluk grafiğindeki yükseliş çatlakların doğru tespit edilme oranının arttığını göstermektedir. MAP (ortalama kesinlik) grafiğindeki yükseliş çatlak tespitindeki ortalama kesinliğin arttığını işaret etmektedir. Doğrulama kayıplarındaki düşüş eğilimi modelin doğrulama seti üzerinde de iyi performans gösterdiğini ve genelleştirme yeteneğinin olduğunu göstermektedir.



Şekil 6. Modelin eğitim sonuç grafikleri



Şekil 7. Modelin tahmin örnekleri

Çatlak tespitine yönelik yapılan çalışmalarda çoğunlukla Inception V3, Alexnet, VGG16 ve ResNet derin öğrenme tabanlı algoritmalar kullanılmıştır. Elde edilen sonuçlar neticesinde kullanılan modellerin doğru tahmin etme yeteneğinin %80 ile %99 arasında değiştiği tespit edilmiştir [14,28-46]. Bu çalışmada Yolov8 algoritması kullanılarak elde edilen doğruluk değeri %95,6, literatürdeki diğer çalışmalar ile kıyaslandığında modelin doğru tahmin etme yeteneğinin oldukça iyi olduğu belirlenmiştir.

Yapı malzemelerinin düzenli bakımı, dayanıklı, güvenli ve uzun ömürlü yapılar için vazgeçilmezdir. Deprem, aşırı yüklenme, zemin kaynaklı ya da çevresel faktörlerden kaynaklı yapıda veya yapının bir bölümünde oluşan hasarlar çeşitli yöntemler kullanılarak dayanım ve dayanıklılığının artırılması amacıyla onarılması gerekmektedir. Beton ve betonarme yapılarda bozulmaların başladığı ilk olarak çatlakların gözlemlenmesi ile anlaşılmaktadır. Dolayısıyla yapının hizmet ömrü boyunca performansının ve güvenliğinin sağlanması için çatlakların hızlı ve doğru tespit edilmesi, çatlak karakterizasyonunun doğru analiz edilmesi ve yapısal bakımın zamanında gerçekleştirilmesi oldukça önemlidir. Sonuç olarak yapı sağlığı ve güvenliği açısından ilk aşama olan çatlak tespitinin, hızlı, doğru, objektif ve otomatik olarak tespit edilmesi hayati öneme sahiptir.

4. SONUÇ

Bu çalışmada, Orta Doğu Teknik Üniversitesi kampüsündeki farklı binalardan elde edilen görüntülerden oluşan METU veri kümesi kullanılarak beton yüzeyindeki çatlakların görüntü işleme yöntemi ile tespit edilmesi amaçlanmıştır. Elde edilen sonuçlara göre, model yüksek gerçek pozitif değeri çatlakları etkin bir şekilde tespit edebilmektedir. Modelin çatlak tahminlerinde çok az yanlış pozitif sonuç verdiği ve farklı sınıfları ayırt etmede yüksek başarı gösterdiği tespit edilmiştir. Modelin yüksek kesinlik puanı gerçek pozitifleri (çatlakları) tespit etmede güvenilir olduğunu göstermektedir. Model belirtilen güven eşik değerinde en iyi dengeli doğruluk ve hatırlama oranına sahiptir ancak yüksek güven eşiklerinde yanlış negatifleri artırabilme ihtimali söz konusudur. Modelin zamanla daha iyi öğrendiği ve performansının arttığı belirlenmiştir. Doğrulama kayıplarındaki düşüş eğilimi modelin doğrulama seti üzerinde de iyi performans gösterdiğini ve genelleştirme yeteneğinin olduğunu göstermektedir.

Farklı makine ve derin öğrenme algoritmaları ile daha geniş veri setleri kullanılarak çalışmaların yapılması ve çok daha hızlı ve doğru tahmin yeteneği olan uygulamaların geliştirilmesi yapısal sağlık izleme açısından oldukça önemli olacaktır.

Çatlak tespiti haricinde dijital görüntü işleme tekniklerinin dayanım tahmini, segregasyon, agrega yüzey özelliklerinin belirlenmesi, beton yüzeyinde oluşan hata deliklerinin tespit edilmesi, karbonatlaşma derinliğinin tespit edilmesi, korozyon gibi betonun farklı özelliklerinin belirlenmesinde kullanılarak zaman, hız, işgücü, enerji, objektiflik açısından avantaj sağlayacak modellerin ve uygulamaların geliştirilmesine ihtiyaç bulunmaktadır.

5. KAYNAKLAR

1. Hamishebahar, Y., Guan, H., So, S., Jo, J., 2022. A comprehensive review of deep learning-based crack detection approaches. *Applied Sciences*, 12(3), 1374.
2. Valença, J., Puente, I., Júlio, E.N.B.S., González-Jorge, H., Arias-Sánchez, P., 2017. Assessment of cracks on concrete bridges using image processing supported by laser scanning survey. *Construction and Building Materials*, 146, 668-678.
3. Gaur, A., Kishore, K., Jain, R., Pandey, A., Singh, P., Wagri, N.K., Roy-Chowdhury, A.B., 2023. A novel approach for industrial concrete defect identification based on image processing and deep convolutional neural networks. *Case Studies in Construction Materials*, 19, e02392.
4. Rahai, M., Esfandiari, A., Bakhshi, A., 2020. Detection of structural damages by model updating based on singular value decomposition of transfer function subsets. *Structural Control and Health Monitoring*, 27(11), e2622.
5. Yu, Y., Rashidi, M., Samali, B., Mohammadi, M., Nguyen, T.N., Zhou, X., 2022. Crack detection of concrete structures using deep convolutional neural networks optimized by enhanced chicken swarm algorithm. *Structural Health Monitoring*, 21(5), 2244-2263.
6. Scott, M., Rezaizadeh, A., Delahaza, A., Santos, C.G., Moore, M., Graybeal, B., Washer, G., 2003. A comparison of nondestructive evaluation methods for bridge deck assessment. *NDT & International*, 36(4), 245-255.
7. Rimkus, A., Podvieszko, A., Gribniak, V., 2015. Processing digital images for crack localization in reinforced concrete members. *Procedia Engineering*, 122, 239-243.
8. Ali, R., Chuah, J.H., Talip, M.S.A., Mokhtar, N., Shoaib, M.A., 2022. Structural crack detection using deep convolutional neural networks. *Automation in Construction*, 133, 103989.

9. Miao, P., Srimahachota, T., 2021. Cost-effective system for detection and quantification of concrete surface cracks by combination of convolutional neural network and image processing techniques. *Construction and Building Materials*, 293, 123549.
10. Ni, T., Zhou, R., Gu, C., Yang, Y., 2020. Measurement of concrete crack feature with android smartphone app based on digital image processing techniques. *Measurement*, 150, 107093.
11. Rucka, M., Wojtczak, E., Knak, M., Kurpińska, M., 2021. Characterization of fracture process in polyolefin fibre-reinforced concrete using ultrasonic waves and digital image correlation. *Construction and Building Materials*, 280, 122522.
12. Sevinç, A., Özyurt, F., 2022. Beton yüzey çatlaklarının tespitinde derin öğrenme mimarilerin kullanılması. *International Journal of Innovative Engineering Applications*, 6(2), 318-325.
13. Vivekananthan, V., Vignesh, R., Vasanthaseelan, S., Joel, E., Kumar, K.S., 2023. Concrete bridge crack detection by image processing technique by using the improved OTSU method. *Materials Today: Proceedings*, 74, 1002-1007.
14. Iraniparast, M., Ranjbar, S., Rahai, M., Nejad, F.M., 2023. Surface concrete cracks detection and segmentation using transfer learning and multi-resolution image processing. In *Structures*, 54, 386-398.
15. Balageas, D., Fritzen, C.P., Güemes, A., 2010. *Structural health monitoring*. John Wiley & Sons.
16. Neville, A.M., 1997. *Properties of concrete*. London: Wiley
17. Sohn, H., Farrar, C.R., Hemez, F.M., Shunk, D.D., Stinemates, D.W., Nadler, B.R., Czarnecki, J.J., 2003. A review of structural health monitoring literature: 1996-2001. Los Alamos National Laboratory, USA, 1, 16.
18. Kabir, S., 2008. Image processing in concrete applications: review and prospective. In *2nd International Structural Specialty Conference on Partnership for Innovation: Instrumentation and Monitoring of Structures*, CSCE Annual Conference, Quebec City.
19. Özgenel, Ç.F., 2019. Concrete crack images for classification. *Mendeley Data*, 2, 2019.
20. <https://docs.roboflow.com/annotate/use-roboflow-annotate>
21. <https://research.google.com/colaboratory>
22. <https://blog.roboflow.com/whats-new-in-yolov8/>
23. Redmon, J., Divvala, S., Girshick, R., Farhadi, A., 2016. You only look once: unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779-788.
24. Erickson, B.J., Kitamura, F., 2021. Magician's corner: 9. performance metrics for machine learning models. *Radiology: Artificial Intelligence*, 3(3), e200126.
25. Ying, X., 2019. An overview of overfitting and its solutions. In *Journal of Physics: Conference Series* 1168, 022022. IOP Publishing.
26. Dietterich, T., 1995. Overfitting and undercomputing in machine learning. *ACM Computing Surveys (CSUR)*, 27(3), 326-327
27. Li, H., Li, J., Guan, X., Liang, B., Lai, Y., Luo, X., 2019. Research on overfitting of deep learning. In *2019 15th International Conference on Computational Intelligence and Security (CIS)*, 78-81, IEEE.
28. Li, S., Zhao, X., 2023. High-resolution concrete damage image synthesis using conditional generative adversarial network. *Automation in Construction*, 147, 104739.
29. Bukhsh, Z.A., Jansen, N., Saeed, A., 2021. Damage detection using in-domain and cross-domain transfer learning. *Neural Computing and Applications*, 33(24), 16921-16936.
30. Dhakal, N., Zihan, Z.U., Elseifi, M.A., Mousa, M.R., Gaspard, K., Fillastre, C.N., 2021. Surface identification of top-down, bottom-up, and cement-treated reflective cracks using convolutional neural network and artificial neural networks. *Journal of Transportation Engineering, Part B: Pavements*, 147(1), 04020080.
31. Kung, R.Y., Pan, N.H., Wang, C.C., Lee, P.C., 2021. Application of deep learning and unmanned aerial vehicle on building maintenance. *Advances in Civil Engineering*, 2021, 1-12.
32. Yang, H., Ni, J., Gao, J., Han, Z., Luan, T., 2021. A novel method for peanut variety identification and classification by improved VGG16. *Scientific Reports*, 11(1), 15756.
33. Dorafshan, S., Azari, H., 2020. Evaluation of bridge decks with overlays using impact echo, a deep learning approach. *Automation in Construction*, 113, 103133.
34. Gong, Y., Luo, J., Shao, H., He, K., Zeng, W., 2020. Automatic defect detection for small metal cylindrical shell using transfer learning and logistic regression. *Journal of Nondestructive Evaluation*, 39, 1-13.
35. Liang, J., 2020. Image classification based on RESNET. In *Journal of Physics: Conference Series*, 1634(1), 012110, IOP Publishing.

36. Wang, Z., Xu, G., Ding, Y., Wu, B., Lu, G., 2020. A vision-based active learning convolutional neural network model for concrete surface crack detection. *Advances in Structural Engineering*, 23(13), 2952-2964.
37. Zhu, J., Zhang, C., Qi, H., Lu, Z., 2020. Vision-based defects detection for bridges using transfer learning and convolutional neural networks. *Structure and Infrastructure Engineering*, 16(7), 1037-1049.
38. Zhu, J., Song, J., 2020. An intelligent classification model for surface defects on cement concrete bridges. *Applied Sciences*, 10(3), 972.
39. Dung, C.V., 2019. Autonomous concrete crack detection using deep fully convolutional neural network. *Automation in Construction*, 99, 52-58.
40. Feng, C., Zhang, H., Wang, S., Li, Y., Wang, H., Yan, F., 2019. Structural damage detection using deep convolutional neural network and transfer learning. *KSCE Journal of Civil Engineering*, 23, 4493-4502.
41. Hüthwohl, P., Lu, R., Brilakis, I., 2019. Multi-Classifer for reinforced concrete bridge defects. *Automation in Construction*, 105, 102824.
42. Hung, P.D., Su, N.T., Diep, V.T., 2019. Surface classification of damaged concrete using deep convolutional neural network. *Pattern Recognition and Image Analysis*, 29(4), 676-687.
43. Słoński, M., 2019. A comparison of deep convolutional neural networks for image-based detection of concrete surface cracks. *Computer Assisted Methods in Engineering and Science*, 26(2), 105-112.
44. Soni, A.N., 2019. Crack detection in buildings using convolutional neural network. *Journal for Innovative Development in Pharmaceutical and Technical Science*, 2(6), 54-59.
45. Özgenel, Ç.F., Sorguç, A.G., 2018. Performance comparison of pretrained convolutional neural networks on crack detection in buildings. In *Isarc. Proceedings of the International Symposium on Automation and Robotics in Construction*, 35, 1-8, IAARC Publications.
46. Silva, W.R.L.D., Lucena, D.S.D., 2018. Concrete cracks detection based on deep learning image classification. In *Proceedings*, 2(8), 489, MDPI.