



DETECTION OF CONCRETE SURFACE CRACKS WITH DEEP LEARNING ARCHITECTURES

Arzu Sevinç^{*1} , Fatih Özyurt¹ 

¹Firat Üniversitesi Mühendislik Fakültesi Yazılım Mühendisliği, Elazığ, Türkiye

Abstract

Original scientific paper

The most basic problem for concrete surfaces is the presence of cracks. These cracks should be identified and repaired as soon as possible to ensure safety. Today, detection of cracks is carried out by human power. Although there is a lot of effort in the determinations made with manpower, the error rate is high. The aim of this study is to provide more accurate and faster detection of cracks. For this, an autonomous system is needed. Some Convolutional Neural Networks (CNN) have been used in the detection of concrete surface cracks. The image data used in this study were collected from the campus buildings of the Middle East Technical University. This data set contains 20000 Negative and 20000 Positive data. Image data was trained using ResNet-50, VGG-16, Inception-V3, Xception deep CNN architectures and MobileNet, ShuffleNet, EfficientNet lightweight CNN architectures. By comparing the data obtained as a result of the training, it was observed how the accuracy changed when fewer parameters were used. When the accuracy rates obtained from the deep CNN architectures and light CNN architectures used were compared, close and successful results were obtained.

Keywords: Crack detection, convolution neural network, lightweight convolution neural network, image processing.

BETON YÜZEY ÇATLAKLARININ TESPİTİNDE DERİN ÖĞRENME MİMARİLERİN KULLANILMASI

Özet

Orijinal bilimsel makale

Beton yüzeyler için en temel problem çatlakların varlığıdır. Bu çatlaklar, güvenliğin sağlanabilmesi için mümkün olan en kısa sürede tespit edilip onarılmalıdır. Günümüzde çatlakların tespit edilmesi insan gücüyle gerçekleştirilmektedir. İnsan gücü ile yapılan tespitlerde fazla emek olmasına karşın hata oranı yüksektir. Bu çalışmanın amacı, çatlakların daha doğru ve hızlı tespit edilmesini sağlamaktır. Bunun için ise otonom bir sisteme ihtiyaç duyulmaktadır. Beton yüzey çatlaklarının tespitinde bazı Evrişimsel Sinir Ağları (CNN) kullanılmıştır. Bu çalışmada kullanılan görüntü verisi Orta Doğu Teknik Üniversitesi kampüs binalarından toplanmıştır. Bu veri setinde 20000 Negatif ve 20000 Pozitif veri bulunmaktadır. Görüntü verileri, ResNet-50, VGG-16, Inception-V3, Xception derin CNN mimarileri ve MobileNet, ShuffleNet, EfficientNet hafif CNN mimarilerini kullanarak eğitildi. Eğitim sonucunda elde edilen veriler karşılaştırılarak, daha az parametre kullanıldığında doğruluğun nasıl değiştiği gözlemlendi. Kullanılan derin CNN mimarileri ve hafif CNN mimarilerinden elde edilen doğruluk oranları karşılaştırıldığında birbirine yakın ve başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Çatlak tespiti, evrişimli sinir ağı, hafif evrişimli sinir ağı, görüntü işleme.

1 Giriş

Beton yüzeylerde zamanla kendiliğinden veya deprem gibi doğal afetlerden kaynaklı bazı çatlamlar meydana gelmektedir. Çatlakların tespiti, olabilecek en kısa sürede ve en az hatayla gerçekleştirilmelidir. Bu sayede maddi ve manevi kayıplar en aza indirilebilir. Düzenli ve sürekli bir inceleme ile çatlaklar hızlıca tespit edilmeli ve onarılmalıdır. Böylece beton yüzeyler korunabilir ve daha dayanıklı hale getirilebilir.

Günümüzde beton bir yüzeyde bulunan çatlak tespiti çoğunlukla insan gücü kullanılarak gerçekleştirilmektedir.

Yetkili bir kişi yüzeyleri inceler ve çatlak tespit ettiği yüzeyin birçok açıdan fotoğrafını çeker ya da dronelar aracılığıyla yüzeylerin fotoğrafları çekilir. Daha sonra bu fotoğraflar tekrar incelenir ve gerekli raporlar hazırlanır. Harcanan emek ve zamana karşın insan gücüyle yapılan işlemlerde hata oranı da yüksektir.

Elazığ da 2020 yılında gerçekleşen deprem sonrasında birçok binada çatlaklar meydana gelmiş ve çatlakların tespiti manuel olarak gerçekleştirilmiştir. Çatlakların tespit edilmesi uzun bir süre devam etmiş ve bu süre içerisinde gerçekleşen daha küçük depremlerde binaların bazıları yıkılmıştır. Bu yıkımlar ise maddi ve manevi bir çok zarara

* Corresponding author.

E-mail address: arzusevinc99@gmail.com (A. Sevinc)

Received 05 April 2022; Received in revised form 07 September 2022; Accepted 05 December 2022

2587-1943 | © 2022 IJIEA. All rights reserved.

Doi: <https://doi.org/10.46460/ijiea.1098046>

sebeplere olmuştur. Benzer olaylar da göz önüne alındığında çatlak tespiti için otonom bir sistemin gerçekleştirilmesi gerektiği görülmektedir. Daha hızlı ve daha doğru sonuçlar ortaya koyan bir sistem sayesinde çatlak tespitleri gerçekleştirilirken bazı kayıplar önlenir.

Çatlak tespiti ile ilgili araştırmalarda genellikle CNN mimarileri kullanılmış ve önerilmiştir. Yapılan bir araştırmada 40000 görüntü verisi kullanılarak OLeNet modeli oluşturulmuştur. OLeNet modelinin doğrulama sığı katman yığını ile gerçekleştirilmiş ve maksimum %99,8 doğruluk elde edilmiştir [1]. Bu çalışma OLeNet mimarisinin başarılı olduğunu ortaya koymaktadır. Ayrıca veri miktarını minimumda tutarak yüksek performans sağlayan yeni bir CNN mimarisi oluşturmanın daha iyi bir seçenek olabileceği de araştırılmaktadır. Bu araştırmada önceden eğitilmiş bir VGG-16 modeli ve özelleştirilmiş, veri sayısının da azaltıldığı, CNN modeli eğitilmiştir. Bu eğitim sonucunda özelleştirilmiş CNN mimarisinin hesaplama süresinin ve karmaşıklığının daha avantajlı olduğu görülmüştür [2]. Son dönemlerde derin CNN mimarilerinin yanı sıra Mask R-CNN ve Faster R-CNN mimarilerinin de bu tarz çalışmalara katkıda bulunacağı araştırılmaktadır. Mask R-CNN mimarisi, çatlak yüzeylerdeki önemli özelliklere karşılık gelen maskeleri elde ederek maliyeti düşürmeyi hedefler [3]. Ayrıca Faster R-CNN kullanılarak hava koşulları da gözlemlenerek çatlakların tespit edilmesi ile ilgili çalışmalarda yapılmıştır. Bu çalışmada 4128 x 2322 çözünürlüğüne sahip görüntüler kullanılmış ve çatlak tespiti analizleri beton bir yolda atış koşulları değiştirilerek yapılmıştır [4]. Faster R-CNN mimarisi ve Mask R-CNN mimarisi karşılaştırıldığında Mask R-CNN mimarisinin çatlak tespiti için daha iyi performans verdiği söylenebilir [5]. Başka bir araştırma da ise 1218 görüntüden oluşan bir veri setine tünel çatlaklarının tespit edilmesi için hafif evrişimli sinir ağı uygulanmıştır. Hafif Evrişimli Sinir Ağı SegNet, U-Net ve DeepCrack ile karşılaştırılmış ve daha hızlı olduğu görülmüştür. [6].

Çatlak tespiti ile ilgili çalışmaların yanı sıra derin öğrenme modellerinin kullanıldığı farklı çalışmalarda incelenmiştir. Çiçeklerin sınıflandırılması ile ilgili yapılan bir çalışma bunlardan biridir [7]. Burada oluşturulan model üç aşamadan geçirilerek oluşturulmuştur. İlk aşamada görüntü verileri, AlexNet, GoogleNet, ShuffleNet, EfficientNet0, ResNet ve InceptionV3 mimarilerini kullanarak sınıflandırılmıştır. İkinci aşamada ise Komşuluk Bileşen Analizi yöntemi kullanılarak oluşturulan özellik haritaları optimize edilmiştir. Son olarak optimize edilen özellik haritası klasik makine öğrenmesi yöntemi ile sınıflandırılmıştır. Oluşturulan bu model %93,49'luk yüksek bir doğruluk oranı elde etmiştir.

Bir diğer çalışma ise beyin tümörünün tespit edilmesi ile ilgilidir. Yapılan bu çalışmada, AlexNet, GoogleNet ve ResNet50 mimarileri kullanılmıştır. Kullanılan bu mimariler arasında ise en yüksek doğruluk oranına ResNet50 mimarisi ile ulaşılmıştır [8].

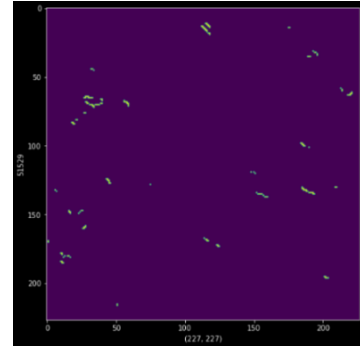
Yapılan bu çalışmada ise farklı çalışmalarda başarılı olduğu görülen mimarilerin bu veri seti üzerinde ki başarıları incelenmiş ve karşılaştırılmıştır. İlk olarak verile görüntü işleme tekniklerinden geçirilmiş daha sonra ise mimarileri kullanılarak sınıflandırılmıştır.

Görüntü işleme teknikleri kullanılarak bir görüntünün incelenmesi ve çatlakların tespit edilmesi, manuel olarak


gerçekleştirilen incelemeyle karşılaştırıldığında daha hızlı ve daha doğru sonuçlar vermektedir. Yapılan bu çalışmada çatlak olan ve olmayan görüntü verileri görüntü işleme teknikleri ile incelenmiştir. Ve bu teknikler kullanılarak çatlaklarda belirgin özelliklerin ortaya çıkması ve tespitinin kolaylaştırılması hedeflenmiştir.

Çatlak tespitlerinde yaygın olarak kullanılan algoritmaların biri Canny Kenar algılama algoritmasıdır. 1986 yılında John Canny tarafından geliştirilen aşamalı bir kenar algılama algoritmasıdır [9]. Kenar tespiti ile görüntü üzerindeki nesnelerin özellikleri çıkarılabilir. Canny algoritmasında genelde köşeler yok sayılmaktadır. Kenar algılama algoritmalarındaki amacın piksel yoğunluklarından kaynaklanan kenar karmaşıklığını azaltmak ve görüntüdeki nesnelere tanımlamak olduğu söylenebilir.

Canny Kenar algoritması kullanılarak çatlak yüzeyler ve çatlak olmayan yüzeyler incelendi. Şekil 1' de Negatif bir görüntü ve Şekil 2' de ise Pozitif bir görüntü Canny Kenar algoritması ile gösterilmektedir. Şekil 2' de çatlak olan alanda bir yoğunluk meydana gelmiş ve çatlak tespit edilmiştir.




Şekil 1. Canny algoritması ile negatif görüntü.




Şekil 2. Canny algoritması ile pozitif görüntü.

Bir diğer görüntü işleme tekniği ise Thresholding (eşikleme) algoritmasıdır. Bu algoritmada ise bir başlangıç değeri belirlenir ve her piksel değeri başlangıç değeri ile karşılaştırılır. Bu karşılaştırma ile görüntü iki sınıfa bölünmektedir, piksel değeri başlangıç değerinden büyük olanlar ve başlangıç değerinden küçük olanlar. Görüntünün birden fazla bölgeye bölünmesi çok seviyeli eşiklemedir. Bölünme ve başlangıç değeri arttıkça yöntemin karmaşıklığı da artmaktadır. Eşikleme algoritması görüntü içerisindeki nesnelere birbirinden ayırmayı amaçlamaktadır.

Şekil 3' de Thresholding algoritması kullanılan Negatif bir görüntü verisi vardır. Negatif bir veride ayırıcı bir özellik fark etmediği için yalnızca zemini karartmıştır.




Şekil 3. Thresholding algoritması ile negatif görüntü.



Şekil 4. Thresholding algoritması ile pozitif görüntü.

Pozitif bir görüntüye uygulanan Thresholding algoritmasında zeminin üzerinde fark ettiği çatlağı ikinci bir nesne olarak alır ve çatlağı zeminden ayırmak için beyaz olarak gösterir. Şekil 4’ de pozitif bir görüntünün negatif bir görüntüden Thresholding algoritması kullanılarak net bir şekilde ayrılacağı görülmektedir.

Orta Doğu Teknik Üniversitesi (ODTÜ) kampüs binalarından toplanan veriler üzerinde uygulanan algoritmalar Şekil 1, 2, 3, 4 gösterilmektedir. Çalışmada kullanılan pozitif ve negatif veriler renkli ve 227x227 piksel özelliklere sahip görüntüler içermektedir. Bu görüntü verileri üzerinde Canny Kenar Algoritması ve Thresholding algoritması uygulanmıştır. Uygulanan bu algoritmalar ile çatlakların belirginleştirilebildiği görülmektedir.



Şekil 5. CNN mimarisi.

2 Materyal ve Metot

2.1 CNN Mimarisi

CNN mimarisi 1980’ lerde geliştirilmeye başlamasına karşın 2012 senesine kadar makine öğrenmesi alanına girememiştir. Büyük veri kümelerinin de kullanılmaya başlanması ile birlikte 2012’de CNN mimarisi bu alanda da kullanılmaya başlanmıştır.




Şekil 10. ResNet-50 CNN mimarisi.

CNN, görüntüdeki nesnelerin özelliklerini çıkarabilen ve nesnelere birbirinden ayırt edebilen bir algoritmadır. Çoklu katmandan oluşan matematiksel bir yapıdır. Evrişimsel sinir ağı, evrişim işlemi kullanır. Evrişim, bir şeklin diğer bir şekil tarafından nasıl değiştirildiğini gösteren yeni bir fonksiyon üreten matematiksel bir işlemdir. CNN, bir giriş katmanı, bir çıkış katmanı ve bu iki katman arasındaki farklı katmanlardan oluşmaktadır. Ortada olan katmanlar matematiksel işlemleri (evrişimleri) gerçekleştiren katmanlardır.

Evrişimli sinir ağında evrişim katmanı çok katmanlı bir çekirdek kullanarak gerekli özellikleri alır ve tam bağlantılı katmanlar ise bu özellikleri kullanarak öğrenir [10].

2.1.1 Evrişim Katmanı

Görüntünün özelliklerini çıkaran katmandır. Bir filtre matrisi oluşturulur ve görüntü üzerinde dolaşır. Görüntü matrisi ile filtre çarpılır ve sonuç kaydedilir. Bu sayede görüntü özellikleri tespit edilebilmektedir.



Şekil 6. Evrişim katmanı.

Şekil 6’ da Görüntü matrisi üzerinde dolaşan bir filtre matrisi ve gerçekleştirdiği işlemlerle evrişim katmanı görülmektedir.

2.1.2 Havuzlama Katmanı


Veri boyutunu ve işlem süresini azaltmak için kullanılır. Boyut azaltılırken önemli bilgiler korunmaktadır. Farklı havuzlama çeşitleri vardır. Bunlardan ilki olan maksimum havuzlama, nöron kümelerinin maksimum değerini kullanır. Ortalama havuzlama ise, bu kümelerden ortalama bir değer çıkarır ve o değeri kullanır. Tüm nöron değerlerinin toplanması ise toplam havuzlamadır.



Şekil 7. Maksimum havuzlama katmanı.

2.1.3 Tam Bağlı Katmanlar

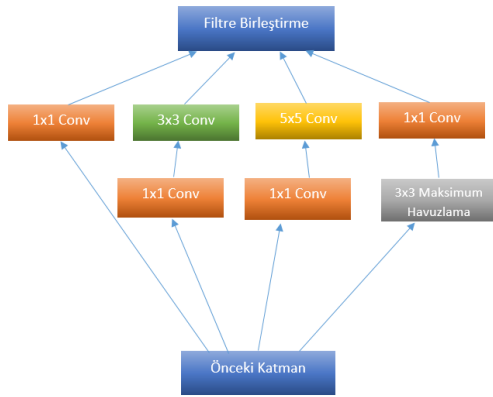
Bu katmanlar, katmanlarda olan nöronların birbiri ile tamamen bağlı olmasından kaynaklı bu ismi almıştır. Matrisler görüntüyü sınıflandırmak için tam bağlı katmanlardan geçmektedir. Şekil 8’ de görüldüğü üzere bu katmandaki tüm nöronlar birbiri ile bağlantılı bir şekildedir.




Şekil 8. Tam bağlı katmanı.

2.1.4 Inception-V3 mimarisi.

Inception-V3 [11], yaygın olarak kullanılan bir CNN mimaridir. Google tarafından oluşturulan Inception-V1 mimarisinin geliştirilmiş halidir. Bu mimari ilk olarak 2015 yılında kullanılmaya başlanmıştır. 42 katmandan oluşmaktadır. Bu mimaride 3x3 evrişim katmanı kullanılmaktadır. Evrişim katmanını azaltmak hesaplama maliyetini de azaltmaktadır.



Şekil 9. Inception-V3 CNN mimarisi.



Şekil 12. VGG-16 CNN mimarisi.

2.2 Hafif CNN Mimarisi

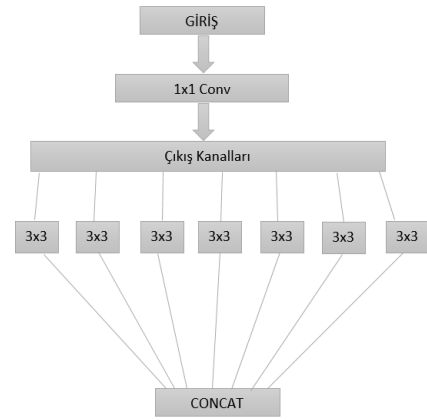
CNN mimarileri özellik çıkarmada yaygın olarak kullanılır ve yüksek performansı ile de önemli bir sinir ağıdır. Eğitim için kullanılan parametre sayısının fazla olması araştırmacıların parametre sayısını azaltmaya yönelik çalışmalar yapmasına sebep olmuştur. Hafif CNN

2.1.5 ResNet-50 Mimarisi

ResNet [12], ILSVRC-2015 yarışmasını kazanmıştır. En fazla 152 evrişim katmanından oluşmaktadır. ResNet mimarilerinde kısa yollar kullanılmaktadır. Bu kısa yollar, bozulmaların azalmasına ve çalışma hızının artmasına katkıda bulunmaktadır. Şekil 10, ResNet mimarisine ait bir resimdir.

2.1.6 Xception Mimarisi

Xception, Google araştırmacıları tarafından geliştirilen derin evrişimli sinir ağıdır. Inception mimarisinin daha derinlemesine eğitilmesi şeklinde tanımlanabilir. Xception mimarisinde 1x1 evrişim katmanları bulunmaktadır. ResNet mimarisinde olduğu gibi bu mimaride de bloklar arasında kısa yollar bulunmaktadır. Basit bir mimariye sahiptir.




Şekil 11. Xception CNN mimarisi.

2.1.7 VGG-16 Mimarisi

Açık kaynaklı bir CNN mimarisidir. 16 katmandan oluşmaktadır. VGG-16 [13] mimarisinde 224 x 224 RGB görüntüleri kullanılmaktadır.


Bu mimaride görüntü ilk olarak evrişimli katmanlardan geçmektedir. Bazı evrişimli katmanları korumak için maksimum havuzlama katmanı takip eder. 3 full bağlantı katmanı bulunmaktadır. Son katman ise softmax katmanıdır. Şekil 12’ da VGG-16 mimarisine ait mimari görülmektedir.

mimarileri, araştırmacıların bu probleme çözüm aramaları ile ortaya çıkmıştır. Hafif CNN mimarisi eğitim için daha az parametre kullanarak ve daha az katman ile uygulanır. Bu durum hesaplama gücünü azaltırken performansın da yüksek olmasını sağlamaktadır. MobileNet, ShuffleNet, EfficientNet iyi performanslar ile çalışan hafif CNN mimarilerinden bazılarıdır.




Şekil 17. VGG-16 kayıp grafiği.

ResNet-50 mimarisinin veri seti üzerindeki eğitimin sonuçları Şekil 18 ve Şekil 19’ de gösterilmektedir. Bu eğitimde elde edilen en yüksek doğruluk oranı 0,9985 olmuştur.




Şekil 18. ResNet-50 doğruluk grafiği.

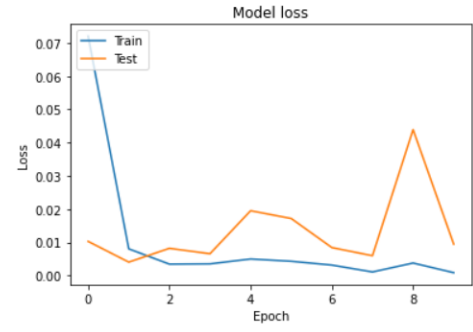


Şekil 19. ResNet-50 kayıp grafiği.

Inception-V3 mimarisi kullanılarak gerçekleştirilen eğitimin en yüksek doğruluk oranı 0,9974’ dür. Başarı ve başarısızlık grafikleri Şekil 20 ve Şekil 21’ de gösterilmektedir.




Şekil 20. Inception-V3 doğruluk grafiği.




Şekil 21. Inception-V3 kayıp grafiği.

Xception mimarisi eğitildiğinde elde edilen sonuçlar aşağıda gösterilmektedir. Eğitim 0,9977’ lik en iyi sonuçla tamamlanmıştır.




Şekil 22. Xception doğruluk grafiği.




Şekil 23. Xception kayıp grafiği.

Hafif CNN mimarisi olan MobileNet mimarisinin eğitiminden 0,9988’ lik bir doğruluk elde edilmiştir. Bu mimaride elde edilen doğruluk ve kayıp grafikleri Şekil 24 ve Şekil 25’ de gösterilmektedir.




Şekil 24. MobileNet doğruluk grafiği.




Şekil 25. MobileNet kayıp grafiği.

ShuffleNet mimarisinin eğitiminden en yüksek 0,9922 doğruluk elde edilmiştir. Bu hafif CNN mimarisinin doğruluk ve kayıp grafikleri aşağıda gösterilmektedir.




Şekil 26. ShuffleNet doğruluk grafiği.




Şekil 27. ShuffleNet kayıp grafiği.

0,9984 doğruluk elde edilen hafif CNN mimarisi EfficientNet mimarisidir. Bu eğitimin sonucunda oluşan doğruluk ve kayıp grafikleri Şekil 28 ve Şekil 29' da gösterilmektedir.



Şekil 28. EfficientNet doğruluk grafiği.



Şekil 29. EfficientNet kayıp grafiği.

Mimarilerin eğitilmesi aşamasında çıktıları normalleştirmek için softmax aktivasyon fonksiyonu kullanılmıştır. Softmax fonksiyonunun normalleştirdiği çıktılarda her değer için olasılığ yorumlar.

Tablo 1' de mimarileri ve aldıkları en yüksek doğruluk oranları gösterilmektedir.

Tablo 1. Mimari isimleri ve doğruluk oranları.

Mimari İsmi	Doğruluk Oranı
0 MobileNet Mimarisi	0,9988
1 VGG-16 Mimarisi	0,9987
2 ResNet-50 Mimarisi	0,9985
3 EfficientNet Mimarisi	0,9984
4 Xception Mimarisi	0,9977
5 Inception-V3 Mimarisi	0,9974
6 ShuffleNet Mimarisi	0,9922

Tabloda da görüldüğü üzere mimarilerin doğruluk oranları arasında çok fazla fark bulunmamaktadır. Hafif CNN mimarilerinden MobileNet mimarisi en yüksek doğruluk oranına sahipken yine hafif CNN mimarisi olan ShuffleNet en az doğruluk oranına sahip mimari olarak görülmektedir. Buna karşın en başarılı sonuç veren mimari ile en az başarılı sonuç veren mimari arasında 0,0066' lık bir fark bulunmaktadır. Parametre sayısının azaltılması eğitimdeki başarıyı olumsuz bir şekilde etkilememiştir.

4 Sonuç

Bu çalışmada Orta Doğu Teknik Üniversitesi kampüs binalarından toplanmış 20000 Negatif ve 20000 Pozitif veri bulunan bir veri seti kullanılmıştır [17]. Derin CNN mimarileri ve hafif CNN mimarileri kullanılarak bu görüntü veri seti eğitildi. Elde edilen doğruluk oranları karşılaştırıldı. Hafif CNN mimarisinin, derin CNN mimarisinden ayrılan en önemli özelliği parametre sayısının azaltılmasıdır. Bu çalışma ile parametre sayısı azaltıldığında doğruluk oranının nasıl değiştiği incelenmiştir. Veriler tüm mimariler ile eğitildi ve test edildi. Eğitim ve test oranları tüm mimarilerde aynı tutularak sonuçların daha doğru yorumlanması istendi. Doğruluk oranları karşılaştırıldığında ise mimariler arasında büyük bir fark olmadığı görüldü. En yüksek başarıya hafif CNN mimarisi olan MobileNet %99,88 doğruluk oranı ile sahipken, en düşük başarıya ise %99,22 doğruluk oranına sahip ShuffleNet mimarisi ulaşmıştır. Bu durumda hafif CNN mimarisinin yüzey çatlak tespit etme çalışması için performansı düşürmediği gibi bu tarz çalışmalarda kullanılmasının avantaj sağladığı söylenebilir.

Bilgilendirme

Bu çalışmada etik kurul onay belgesi gerekli değildir. Yazarlar arasında herhangi bir çıkar çatışması yoktur.

Kaynakça

- [1] Kim, B., Yuvaraj, N., Sri Preethaa, K. R., & Arun Pandian, R. (2021). Surface crack detection using deep learning with shallow CNN architecture for enhanced computation. *Neural Computing and Applications*, 33(15), 9289-9305.
- [2] Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688.
- [3] Attard, L., Debono, C. J., Valentino, G., Di Castro, M., Masi, A., & Scibile, L. (2019, September). Automatic crack detection using mask R-CNN. In *2019 11th international symposium on image and signal processing and analysis (ISPA)* (pp. 152-157). IEEE.
- [4] Hacıfendioğlu, K., & Başağa, H. B. (2022). Concrete road crack detection using deep learning-based faster R-CNN method. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 46(2), 1621-1633.
- [5] Xu, X., Zhao, M., Shi, P., Ren, R., He, X., Wei, X., & Yang, H. (2022). Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN. *Sensors*, 22(3), 1215.
- [6] Liao, J., Yue, Y., Zhang, D., Tu, W., Cao, R., Zou, Q., & Li, Q. (2022). Automatic Tunnel Crack Inspection Using an Efficient Mobile Imaging Module and a Lightweight CNN. *IEEE Transactions on Intelligent Transportation Systems*.
- [7] Bingöl, H. (2022). Derin Öğrenme Modellerinde Komşuluk Bileşen Analizi Yöntemi Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 439-447.
- [8] Bingöl, H., & Alatas, B. (2021). Classification of brain tumor images using deep learning methods. *Turkish Journal of Science and Technology*, 16(1), 137-143.
- [9] Wikipedia (2014). *Canny Edge Detector* Retrieved 24 June, 2022 from https://en.wikipedia.org/wiki/Canny_edge_detector
- [10] Niu, S., & Srivastava, V. (2022). Simulation trained CNN for accurate embedded crack length, location, and orientation prediction from ultrasound measurements. *International Journal of Solids and Structures*, 242, 111521.
- [11] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- [12] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [13] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [14] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [15] Ma, N., Zhang, X., Zheng, H. T., & Sun, J. (2018). Shufflenet v2: Practical guidelines for efficient cnn architecture design. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 116-131).
- [16] Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- [17] Çağlar, F. O., & Özgenel, R. (2019). Concrete crack images for classification. *Mendeley Data*, 2.
- [18] Pujara, A. (2014). *Image Classification with MobileNet* 04 June, 2020 from https://en.wikipedia.org/wiki/Canny_edge_detector
- [19] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).