

Deprem Sonrası Bina Yüzeylerinde Meydana Gelen Çatlakların Tespitinde Sınıflandırma Modellerinin Karşılaştırılması

Abdullah ŞENER*¹ ORCID 0000-0002-8927-5638
Burhan ERGEN² ORCID 0000-0003-3244-2615

¹Bingöl Üniversitesi, Genç Meslek Yüksekokulu, Bilgisayar Teknolojileri
Bölümü, Bingöl
²Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
Bölümü, Elazığ

Geliş tarihi: 10.02.2022 Kabul tarihi: 27.12.2022

Atıf şekli/ How to cite: ŞENER, A., ERGEN, B., (2022). Deprem Sonrası Bina Yüzeylerinde Meydana Gelen Çatlakların Tespitinde Sınıflandırma Modellerinin Karşılaştırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(4), 899-909.

Öz

Deprem, can ve mal kaybına neden olan bir doğal afettir. Deprem sonrası hasarların ve can kayıplarının en aza indirilebilmesi için ön hazırlıkların yapılması büyük önem taşımaktadır. Yapılan çalışmada duvar yüzeylerinde meydana gelen küçük veya büyük çaplı çatlakların tespit edilmesi işlemleri, son yıllarda bilgisayar alanında popüler çalışma konularından biri olan görüntü sınıflandırma yöntemleriyle gerçekleştirilmiştir. Çalışmada içerisinde çatlakların bulunduğu ve bulunmadığı 40000 duvar görüntülerinden oluşan veri seti kullanılmıştır. Sınıflandırma işlemlerinde DenseNet-201, VGG-19 ve Xception modelleri ayrı ayrı kullanılmıştır. Modeller kullanılarak görüntüler özellik haritaları çıkartılmıştır. Bir sonraki aşamada ise DenseNet-201 ile %99, VGG-19 ile %94 ve Xception modeli ile %99 doğruluk oranı ile sınıflandırma işlemleri gerçekleştirilmiştir. Gerçekleştirilen sınıflandırma işlemlerindeki başarılar göz önüne alındığında hasar tespiti işlemlerinde kullanılacak alternatif bir yöntem sunulmaktadır.

Anahtar Kelimeler: Görüntü sınıflandırma, Yapay sinir ağları, Derin öğrenme, DenseNet-201, Xception, VGG-19

Comparison of Classification Models for Detection of Cracks in Building Surfaces After Earthquake

Abstract

An earthquake is a natural disaster that causes loss of life and property. It is of great importance to make preparations to minimize the damage and loss of life after an earthquake. In the study, the detection of small or large cracks on the wall surfaces was performed using image classification methods, which are one of the most popular working topics in the computer field in recent years. A dataset of 40000 wall

*Sorumlu yazar (Corresponding author): Abdullah ŞENER, asener@bingol.edu.tr

images with and without cracks was used for the study. DenseNet-201, VGG-19 and Xception models were used separately for the classification. Feature maps of the images were extracted using the models. In the next step, the classification processes were performed with DenseNet-201 with 99% accuracy, with VGG-19 with 94% accuracy, and with the Xception model with 99% accuracy. Considering the success in the classification processes, an alternative method that can be used in damage assessment is presented.

Keywords: Image classification, Artificial neural networks, Deep learning, DenseNet-201, Xception, VGG-19

1. GİRİŞ

Deprem, yer kabuğunda beklenmedik bir anda ortaya çıkan enerji sonucunda meydana gelen yeryüzü sarsıntısı olayıdır [1]. Deprem çoğu doğal olaylar gibi öngörülemez bir yapıya sahiptir. Ancak bir bölgede daha önce meydana gelmiş depremler sonrası yapılan çalışmalar aracılığıyla ilerleyen vakitlerde meydana gelebilecek depremler için ön hazırlıklar yapılabilir. Ön hazırlıkların başında binalarda deprem sonrası meydana gelen küçük veya büyük çaplı çatlak hasarlarının tespit edilip düzeltilmesidir. Günümüzde binalarda meydana gelen çatlakları belirlemek için bir dizi pahalı araçlara ve bu araçlardan elde edilen bilgileri insanların tecrübelerine göre yorumlanmasına ihtiyaç duyulmaktadır. Bu işlemlerin bilgisayarlı görme teknikleri kullanılarak tek bir görüntü üzerinden gerçekleştirilmesi hem maliyet hem de zaman açısından daha faydalı olacaktır. Tek bir görüntü üzerinden bina duvarlarında meydana gelen çatlakların tespiti insanlar için basit ve kolay bir işdir. Bu işlem, otonom bir sistem için daha yüksek bir zorluk seviyesine sahiptir. Tek bir görüntüyü giriş verisi olarak alan iyi bir sınıflandırıcı sistem tasarlayarak doğruluk oranı yüksek hasar tespiti gerçekleştirilebilir. Yapılan çalışmada görüntü sınıflandırma yöntemleri kullanılarak binalar üzerinde çatlak tespiti yapılmaya çalışılmış ve başarılı sonuçlar elde edilmiştir.

Son yıllarda, yeni teknolojilerin tanıtılmasıyla birlikte bilgisayarlı görme alanında gelişmeler hızlı bir şekilde gerçekleşmektedir. Bu gelişmelerin bir sonucu olarak, bilgisayarlı görme modellerinin görüntü tanıma, nesne algılama, görüntü

sınıflandırma vb. ile ilgili birçok konunun popülerleşmesini sağlamıştır. Görüntü sınıflandırma yöntemi son yıllarda yapılan çalışmalar göz önüne alındığında hemen hemen her alanda kullanılmaya başlaması popüler bir konu olduğunun göstergesidir [2]. Görüntü sınıflandırma işlemi; kullanıcının belirlediği özelliklere göre görüntüyü meydana getiren piksellerin her bir görüntü üzerindeki diğer piksellerle karşılaştırılıp benzerlik oranı yüksel olanların aynı sınıflarda toplanması işlemidir [3]. Görüntü sınıflandırma işleminin temel amacı aynı spektral özelliklere sahip görüntüleri gruplandırmaktır [4].

Literatür çalışmalarında görüntü sınıflandırma yöntemleri kullanılarak görüntüler üzerinde çatlak, kırık, bozukluk vb. gibi özelliklerin tespiti ile ilgili birçok çalışma mevcuttur. Bu çalışmalardan bazıları incelenecek olursa; Thiago Rateke ve Aldo Von Wangenheim yaptıkları çalışmada yol yüzeylerinde meydana gelen farklı boyuttaki çatlak ve hasarların tespit edilmesi işlemini gerçekleştirmişlerdir [5]. Wilson Ricardo Leal da Silva ve Diogo Schwerz de Lucena derin öğrenmede görüntü sınıflandırmaya dayalı beton çatlakları tespiti üzerine çalışmışlardır [6]. Yaptıkları çalışmada beton yüzeylerdeki çatlakları tespit etmek için makine öğrenimi tabanlı bir model geliştirmeyi amaçlamaktadır. Diogo Duarte ve arkadaşları Evrimsel Sinir Ağları ile Bina Hasarlarının Görüntü Sınıflandırması ile tespiti üzerinde çalışmışlardır [7]. Hiroya Maeda ve arkadaşları Akıllı Telefon Görüntüleriyle Derin Sinir Ağlarını Kullanarak Yol Hasar Tespiti ve Sınıflandırması üzerine çalışmışlardır [8]. Niannian Wang ve arkadaşları Durağan

Görüntülere Dayalı Evrişimli Sinir Ağlarını Kullanan Yığma Tarihi Yapılar için Hasar Sınıflandırması üzerine çalışmışlardır [9]. Abhishek Reddy ve arkadaşları Yapay zekâ tabanlı görüntü analitiği kullanılarak rüzgâr türbini kanatlarındaki Çatlakların ve hasarların tespiti üzerine çalışmışlardır [10]. ASM Shihavuddin ve arkadaşları Birleşik bir derin öğrenme yaklaşımı kullanarak yenilenebilir enerji kurulumlarının görüntü tabanlı yüzey hasarı tespiti üzerine çalışmışlardır [11]. K.Y. Choi ve S.S. Kim Dijital görüntü işleme ile yüzey korozyon hasarı türlerinin morfolojik analizi ve sınıflandırılması üzerine çalışmışlardır [12].

Yapılan çalışmada görüntü sınıflandırma yöntemleri kullanılarak bina yüzeylerinde meydana gelen çatlaklar tespit edilmeye çalışılmıştır. Bu çalışmada DenseNet, VGG-19 ve Xception görüntü sınıflandırma modelleri ayrı ayrı kullanılarak bina yüzeyinde meydana gelen büyük veya küçük çaplı çatlaklar modele verilen görüntüler üzerinde tespit edilmiştir. Elde edilen sonuçlara göre kullanılan modeller karşılaştırılmıştır.

Çalışmanın diğer bölümleri hakkında özet bilgiler şu şekildedir; 2. bölümde Materyal ve Metotlardan bahsedilmiştir. Ayrıca yine bu bölümde yapılan

çalışmanın detayları ile ilgili bilgiler yer almaktadır. Deneysel analiz sonuçlarına 3. bölümde yer verilmiştir. Tartışma ve sonuçlar ise 4. ve 5. bölümde yer almaktadır.

2. MATERYAL VE METOD

Bu bölümde sınıflandırma işlemini gerçekleştirilen veri seti ve sınıflandırma işleminde kullanılan modeller hakkında bilgiler içermektedir.

2.1. Veri Seti

Yapılan çalışmada kullanılacak sınıflandırma modellerinin performanslarını değerlendirmek için içerisinde çatlakların bulunduğu ve bulunmadığı görüntülerden oluşan bir veri seti kullanılmıştır. Veri seti; çatlakların bulunduğu pozitif etiketli klasörde 227 x 227 piksel boyutlarında RGB kanallı 20000 görüntü, çatlakların bulunmadığı negatif etiketli klasörde 227 x 227 piksel boyutlarına RGB kanallı 20000 görüntü ile birlikte toplamda 40000 görüntüden oluşmaktadır [13]. Çalışmada kullanılan 2000 görüntünün %40'ı eğitim, %30'u doğrulama ve %30'u ise test için kullanılmıştır. Veri setini oluşturan görüntülerden bazıları Şekil 1'de gösterilmiştir.



Şekil 1. Veri setini temsil eden örnek görüntüler a) Çatlak pozitif, b) Çatlak negatif [13]


2.2. Derin Öğrenme

Derin öğrenme, üzerinde çalıştığı veri setine uygun sonuçlar üretebilen veya tahmin edebilen birden fazla katmandan oluşmuş makine öğrenme yöntemleridir. Derin öğrenmede amaç, içerdiği yapay sinir ağını kullanarak üzerinde çalıştığı verilerden yeni veriler üretmektir. Derin öğrenme yöntemleri arasında popülerliği en yüksek olan yöntem Evrişimli sinir ağı (CNN) mimarisidir [14]. CNN mimarisi görüntüler üzerinde sınıflandırma işlemlerini gerçekleştirirken, insan beyninin görsel korteksinin çalışma prensibine benzer şekilde ortak özelliklere sahip görüntüleri tanımakta ve bir araya getirmektedir [15]. CNN mimarisinin yapısı evrişim katmanı, doğrusal olmayan katman, havuzlama katmanı, düzeltme katmanı ve tamamen bağlı katmanlarının birleşiminden oluşmaktadır [16]. CNN mimarisini oluşturan katmanların özelliklerine bakıldığında; matematiksel işlemlerin yoğun bir şekilde gerçekleştiği katman evrişim katmanıdır. CNN mimarisinin temelini evrişim katmanı temsil etmektedir. Evrişim katmanında düşük ve yüksek seviyeli özellik saptama işlemi görüntüler üzerinde bazı filtreler uygulayarak gerçekleştirilmektedir. Bir evrişimli sinir ağındaki doğrusal olmayan bir katman, evrişimsel katman tarafından oluşturulan özellik haritasını alan ve çıktı olarak aktivasyon haritasını oluşturan bir aktivasyon fonksiyonundan oluşur. Aktivasyon işlevi, giriş hacmi üzerinde eleman bazında bir işlemdir ve bu nedenle giriş ve çıkışın boyutları aynıdır. Havuzlama katmanı, aktivasyon haritalarının uzamsal boyutunu küçültmekten sorumludur. Genel olarak, hesaplama gereksinimlerini ağ üzerinden aşamalı olarak

azaltmak için diğer katmanların (evrişimli ve doğrusal olmayan katmanlar) birden fazla aşamasından sonra kullanılırlar. Düzeltme Katmanının görevi CNN mimarisinin son katmanı olan tam bağlı katmanın girişi için verileri hazırlamaktır. Genellikle bu katman kendisine gelen verileri tek boyutlu bir matrise dönüştürerek bu işlemi gerçekleştirir. Tam bağlı katman giriş katmanı ve çıkış katmanı arasında ilişki kurma işlemini gerçekleştirmektedir [17].

2.3. DenseNet

DenseNet; yoğun bağlantılı evrişim sinir ağıdır. DenseNet, görüntüler üzerinde nesne tanıma ve sınıflandırma işlevleri için geliştirilen yapay sinir ağlarındaki keşiflerden biridir. DenseNet, yapı olarak ResNet'in mimarisine oldukça benzer. İki mimari arasında bazı temel farklılıklar vardır. Bu farklılıklara bakıldığında; ResNet, önceki katmanda elde ettiğini bilgileri bir sonraki katmanla birleştiren bir toplama yöntemi kullanırken, DenseNet önceki katmanda elde ettiği bilgileri bir sonraki katmanla birleştirme yöntemini kullanmaktadır. DenseNet (Yoğun bağlantılı evrişim ağı), her katmanı diğer katmanlara ileriye doğru bir şekilde bağlamaktadır. DenseNet mimarisinde her katman önceki tüm katmanların özelliklerini girdi olarak kullanmakta ve katmandaki kendi özellikleri de sonraki katmanlara girdi olarak vermektedir [18]. DenseNet mimarilerinin avantajı özellik yayılımını sağlamak ve özelliğin yeniden kullanılmasına olanak sağlayarak parametre sayısını azaltmasıdır [19]. Şekil 2'de örnek bir DenseNet mimarisi gösterilmektedir [20].




Şekil 2. DenseNet mimarisi [20]

2.4. VGG-19

VGG-19, 24 katman derinliğine sahip evrişimsel bir sinir ağıdır. Bu katmanları 16 evrişimsel, 5 havuzlama ve 3 tam bağlantılı katmandan oluşmaktadır [21]. ImageNet veritabanında bulunan bir milyondan fazla görüntü üzerinde önceden eğitilmiştir. VGG-19 ağı, 224 x 224

piksel boyutlarında bir görüntü girişine sahiptir. VGG-19 mimarisi incelendiğinde yaklaşık olarak 138 milyon parametreden oluştuğu görülmektedir [22]. VGG-19, parametre sayısını azaltmak için evrişimsel katmanda 3x3 piksel boyutunda filtreler kullanmaktadır. Şekil 3'te VGG-19 mimarisi gösterilmektedir.

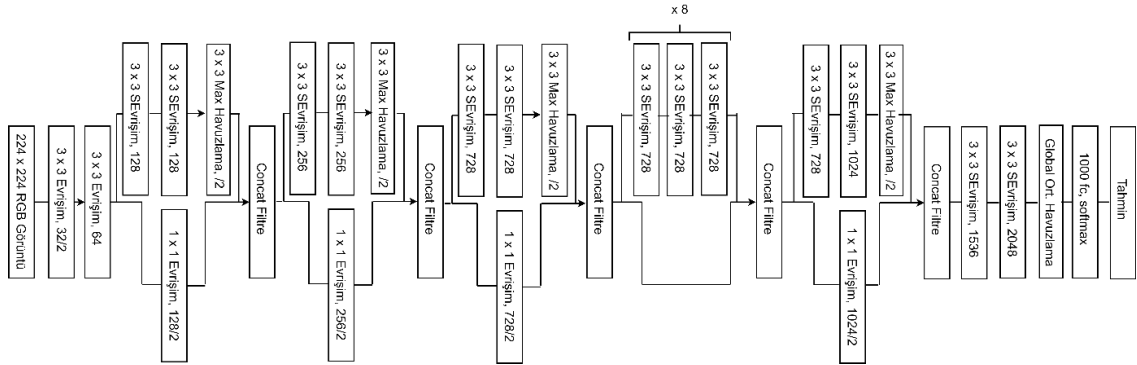


Şekil 3. VGG-19 mimarisi

2.5. Xception

GoogLeNET (Inception V1), Google mühendisleri tarafından "Network-In-Network" çalışmasından esinlenerek oluşturulmuştur [23]. Daha sonra Inception V2 ve Inception V3 versiyonları geliştirilmiştir [24]. Xception mimarisi, standart Inception modüllerini derinlemesine ayrılabilir evrişimle değiştiren Inception mimarisinin bir uzantısıdır [25,26]. ImageNet veritabanında

bulunan bir milyondan fazla görüntü üzerinde önceden eğitilmiştir. Xception ağı, 224 x 224 piksel boyutlarında bir görüntü girişine sahiptir. Girdi olarak alınan verileri sıkıştırılmış parçalara bölmek yerine, her bir çıktı kanalı için uzamsal korelasyonları ayrı eşler ve kanallar arası korelasyona ulaşmak için 1 x 1 derinlikte evrişim gerçekleştirir. Xception mimarisi Şekil 4'te gösterilmektedir.



Şekil 4. Xception mimarisi

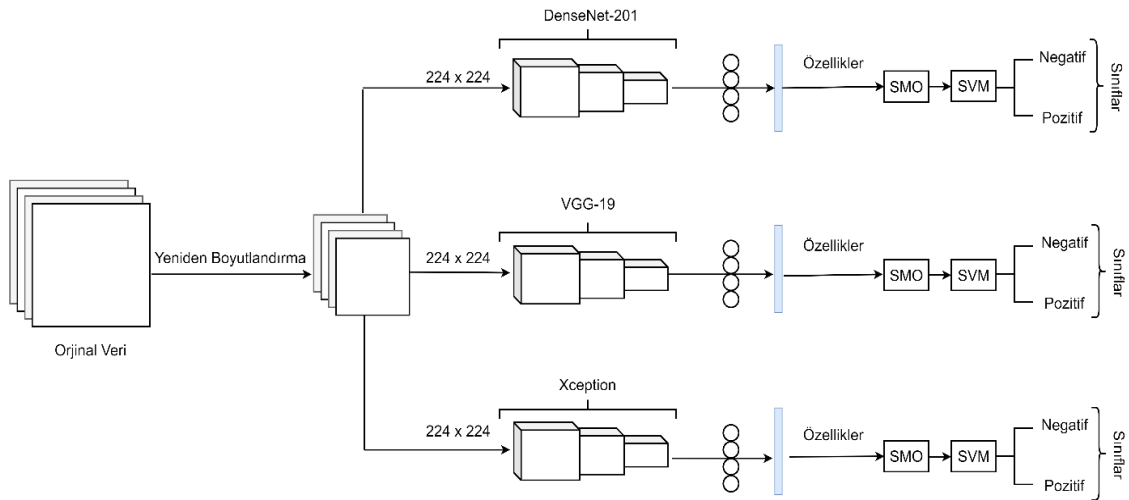
2.6. Çalışma Detayları

Yapılan çalışmada bina duvarları üzerinde meydana gelen küçük veya büyük ölçekli çatlakların tespit edilmesi için sınıflandırma işlemleri gerçekleştirilmiştir. Yapılan çalışmanın

genel tasarımı Şekil 5'te gösterilmektedir. Çalışmada ilk olarak görüntülerin yeniden boyutlandırılması işlemi yapılmıştır. Bu işlemin yapılma amacı sınıflandırma işlemi hızlandırmak ve bilgisayar hafızasında fazla yer tüketmesini önlemektir. Yeniden boyutlandırma işleminde

görüntüler önceden belirlenmiş sabit bir boyuta getirilir. Görüntü boyutları sabitleştirilirken gereğinden fazla küçülmemesine dikkat edilmelidir. Görüntüler gereğinden fazla küçültülürse bu sefer görüntünün sınıflandırılması için gerekli olan bilgi çıkarımı zorlaşacaktır. Bu bilgiler doğrultusunda veri setindeki görüntüler sınıflandırma işlemlerine geçilmeden önce 224 x

224 piksel çözünürlüğüne düşürülmüştür. Bir sonraki aşamada yeniden boyutlandırılmış görüntülerin özellik çıkarımı işlemi DenseNet-201, VGG-19 ve Xception modellerinde ayrı ayrı gerçekleştirilmiştir. Daha sonraki aşamada ise eğitim ve test işlemleri gerçekleştirilerek sınıflandırma işlemleri yapılmıştır.



Şekil 5. Gerçekleştirilen çalışmanın genel tasarımı

3. DENEYSEL SONUÇLAR VE ARAŞTIRMA BULGULARI

Yapılan çalışmada sınıflandırma işlemlerini gerçekleştirilen modellerin performanslarını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Karmaşıklık matrisi oluşturulurken kullanılan terimler; DP: Doğru Pozitif, YP: Yanlış Pozitif, DY: Doğru Negatif ve YN: Yanlış Negatiftir. Bu terimler kullanılarak ayrıca modelin Kesinlik, Duyarlılık, Doğruluk ve F1-Skor değerleri hesaplanabilir. Bu değerleri hesaplamak için aşağıda gösterilen 1, 2, 3 ve 4 te verilen matematiksel işlemlerle hesaplanmaktadır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (1)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2)$$

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

$$F1-Skor = \frac{2DP}{DP + YP + YN} \quad (4)$$

Yapılan çalışmada DenseNet-201, VGG-19 ve Xception modellerinin eğitim ve test işlemleri PyCharm 2021 ile gerçekleştirilmiştir. Modellerde kullanılan veri seti dosyalarının işlenmesi için Python 3.6 kullanılmıştır. Çalışmada kullanılan bilgisayarın işletim sistemi 64-bit Windows 10'dur. Diğer donanım bilgileri ise NVIDIA GeForce® RTX™ 3060 6 GB ekran kartı, 11. Nesil Intel® Core™ i7 2,3 GHz (24M Önbellek, 4,6 GHz'e kadar, 8 Çekirdek) işlemci ve 16 GB bellek.

Yapılan deneysel çalışmaların sonuçları incelendiğinde; her bir modelin eğitim ve test

aşamaları toplamda DenseNet-201 ve VGG-19'da 25, Xception da 20 adımda gerçekleştirilmiştir. İncelen ilk model DenseNet-201'dir. İlk adımında eğitim kaybı ve doğrulama kaybı 0,1034 ve 0,0182 değerlerini gösterirken eğitim doğruluğu ve doğrulama doğruluğu 0,97 ve 0,99 değerlerini göstermiştir. İlk beş adım sonrasında eğitim ve doğrulama kaybı 0,0181 ve 0,0063 değerlerini gösterirken. Eğitim ve doğrulama doğruluğu 0,9933 ve 0,9967 değerlerini göstermiştir. İlk on adım sonrasında eğitim ve doğrulama kaybı 0,0063 ve 0,0133 değerlerini göstermiştir. Eğitim ve doğrulama doğruluğunda ise 0,9992 ve 0,9933 değerleri elde edilmiştir. On beş adım sonrasında eğitim ve doğrulama kaybı 0,0032 ve 0,0168 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9992 ve 0,9967 değerlerini gösterdiği gözlemlenmiştir. Yirmi adım sonrasında eğitim ve doğrulama kaybı değerleri 0,0150 ve 0,0212 hesaplanırken, eğitim ve doğrulama doğruluğu değerleri 0,9967 ve 0,9933 hesaplanmıştır. Son olarak yirmi beş adım sonrasında eğitim ve doğrulama kaybı değerleri 0,0052 ve 0,0222 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9992 ve 0,9933 değerlerini göstermiştir.


Deneysel çalışmada incelen ikinci model VGG-19'dur. İlk adımında eğitim kaybı ve doğrulama kaybı 0,5102 ve 0,3486 değerlerini gösterirken eğitim doğruluğu ve doğrulama doğruluğu 0,8343 ve 0,92 değerlerini göstermiştir. İlk beş adım sonrasında eğitim ve doğrulama kaybı 0,1263 ve 0,19 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9679 ve 0,9267 değerlerini göstermiştir. İlk on adım sonrasında eğitim ve doğrulama kaybı 0,0877 ve 0,1353 değerlerini göstermiştir. Eğitim ve doğrulama doğruluğunda ise 0,9686 ve 0,955 değerleri elde edilmiştir. On beş adım sonrasında eğitim ve doğrulama kaybı 0,0647 ve 0,118 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9750 ve 0,9583 değerlerini gösterdiği gözlemlenmiştir. Yirmi adım sonrasında eğitim ve doğrulama kaybı değerleri 0,0557 ve 0,1057 hesaplanırken, eğitim ve doğrulama doğruluğu değerleri 0,9843 ve 0,9583 hesaplanmıştır. Son olarak yirmi beş adım sonrasında eğitim ve doğrulama kaybı 0,0476 ve 0,1487 değerlerini gösterirken, eğitim ve

doğrulama doğruluğu 0,9893 ve 0,945 değerlerini göstermiştir.


Deneysel çalışmada incelenen üçüncü model Xception'dur. İlk adımında eğitim kaybı ve doğrulama kaybı 0,4166 ve 0,1722 değerlerini gösterirken eğitim doğruluğu ve doğrulama doğruluğu 0,8736 ve 0,97 değerlerini göstermiştir. İlk beş adım sonrasında eğitim ve doğrulama kaybı 0,0542 ve 0,0673 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9879 ve 0,9883 değerlerini göstermiştir. İlk on adım sonrasında eğitim ve doğruluk kaybı 0,0287 ve 0,0427 değerlerini göstermiştir. Eğitim ve doğrulama doğruluğunda ise 0,9950 ve 0,9917 değerleri elde edilmiştir. On beş adım sonrasında eğitim ve doğrulama kaybı 0,0232 ve 0,0301 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9929 ve 0,995 değerlerini gösterdiği gözlemlenmiştir. Yirmi adım sonrasında eğitim ve doğrulama kaybı değerleri 0,0169 ve 0,0363 hesaplanırken, eğitim ve doğrulama doğruluğu değerleri 0,9957 ve 0,9867 hesaplanmıştır. Son olarak yirmi beş adım sonrasında eğitim ve doğrulama kaybı 0,0476 ve 0,1487 değerlerini gösterirken, eğitim ve doğrulama doğruluğu 0,9893 ve 0,945 değerlerini göstermiştir.

4. TARTIŞMA

Günümüzde deprem sonrası meydana gelen bina çatlaklarının tespit edilip onarılması büyük önem taşımaktadır. Bunun nedeni daha sonra meydana gelebilecek küçük veya büyük çaplı deprem sonrası hasarı minimuma indirmektir. Yapılan çalışmada DenseNet-201, VGG-19 ve Xception modelleri ayrı ayrı kullanılarak bina duvarlarında meydana gelen çatlakların tespit edilip sınıflandırılması işlemleri gerçekleştirilmiştir. Sınıflandırma işlemlerinde başarılı sonuçlar elde edilmiştir. Elde edilen sonuçlara göre modellerin gerçek ve sınıflandırıcının tahmin ettiği sınıfların gösterildiği karmaşıklık matrisleri Şekil 6'da gösterildiği gibidir. Sınıflandırma işleminde kullanılan modellerin eğitim-doğrulama doğruluğu grafiği ile eğitim- doğrulama kaybı grafiği Şekil 7'de gösterilmiştir.



Şekil 6. Modellerin karmaşıklık matrisleri



Şekil 7. Eğitim ve doğrulama grafikleri

Sınıflandırmada işleminde kullanılan modellerinin karışıklık matrislerinin metrik değerleri Çizelge 1’de gösterilmektedir. Modellerin karmaşıklık matrisleri ve karmaşıklık matrislerini oluşturan metrik değerler karşılaştırıldığında; DenseNet-201 ve Xception modelleri %99 doğruluk başarısı gösterirken, VGG-19 ise %94 doğruluk başarısı göstermiştir. Kullanılan veri seti

referans alınarak kullanılan modeller doğruluk başarılarına göre incelendiğinde son sırayı VGG-19 modeli almıştır. Aynı koşullar altında DenseNet-201 ve Xception modellerinin doğruluk başarıları %99,33 ve %99,86 değerlerini gösterdiği tespit edilmiştir. Bu şartlar altında modeller arasında birinci sırayı Xception modeli alırken, ikinci sırayı ise DenseNet-201 modeli almıştır.

Çizelge 1. Modellerin karmaşıklık matrisinin metrik değerleri

Model	Sınıflar	Kesinlik%	Duyarlılık%	F1-Skor%	Doğruluk%
DenseNet-201	Negatif	100	99	99	99
	Pozitif	99	100	99	
VGG-19	Negatif	99	89	94	94
	Pozitif	88	99	94	
Xception	Negatif	100	98	99	99
	Pozitif	98	100	99	

5. SONUÇ

Yapılan çalışmada içerisinde çatlakların bulunduğu ve bulmadığı toplamda 40000 görüntüden oluşan veri setinin %5’i kullanılarak görüntüler üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemleri üç farklı model ile yapılmıştır. Daha sonra ise elde edilen sonuçlar karşılaştırılmıştır. Çalışmada yapılan sınıflandırma işleminin amacı; bir bölge içerisinde önceden gerçekleşen depremler sonrası oluşan hasarların tespitini otonom ve masrafsız bir şekilde bilgisayarlı göreme işlemleri ile gerçekleştirmektir. Yapılan çalışmada depremler sonrası oluşan

hasarlar bina yüzeylerinde meydana gelen çatlaklar referans alınarak gerçekleştirilmiştir. Oluşan hasarların tespiti ilerleyen vakitlerde meydana gelebilecek depremlerin ön hazırlığı için büyük önem taşımaktadır. Kullanılan veri seti göz önünde bulundurulduğunda elde edilen sonuçlara göre en iyi sınıflandırma işlemi Xception modeli gerçekleştirmiştir. Doğruluk başarısında çok az bir farkla Xception modelini DenseNet-201 ve VGG-19 modelleri takip etmiştir. Yapılan çalışma ile aynı veri setini kullanan diğer çalışmaların analiz sonuçları ve gerçekleştirilen çalışmanın analiz sonuçları Çizelge 2’de gösterilmektedir.

Çizelge 2. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması

Makale	Yıl	Model/Model	Doğruluk%
Silva and Lucena [6]	2018	VGG-16	92,27
Fan, Z and etc. [27]	2018	CNN	92,44
Yapılan çalışma	2022	Xception	99,29
		VGG-19	94,5
		DenseNet-201	99,33

Çizelge 2 incelendiğinde Yapılan çalışmada kullanılan 3 modeli doğruluk oranları, diğer iki çalışmada elde edilen doğruluk oranlarına kıyasla daha başarılı olduğu görülmektedir. Gerçekleştirilen sınıflandırma işlemlerindeki başarılar göz önüne alındığında bu işlemlerin maliyetinin az olması ve kısa zamanda sonuç vermesi binalar üzerinde meydana gelebilecek hasarların tespitinin yapılabilmesinde iyi bir alternatif yol olarak karşımıza çıkmaktadır.

6. KAYNAKLAR

1. İşçi, C., 2008. Deprem Nedir ve Nasıl Korunuruz. Yaşar Üniversitesi E-Dergisi, 3(9), 959.
2. Liu, X., Deng, Z., Yang, Y., 2019. Recent Progress in Semantic Image Segmentation. Artificial Intelligence Review, 52(2), 1089-1106.
3. Campbell, J.B., Wynne, R.H., 2011. Introduction to Remote Sensing. Guilford Press, 670.
4. Gao, J., 2009. Digital Analysis of Remotely Sensed Imagery. McGraw-Hill Education, 674.
5. Rateke, T., Von Wangenheim, A., 2021. Road Surface Detection and Differentiation Considering Surface Damages. Autonomous Robots, 45(2), 299-312.
6. Silva, W.R.L.D., Lucena, D.S.D., 2018. Concrete Cracks Detection Based on Deep Learning Image Classification. In Proceedings, MDPI AG, 2(8) 489.
7. Duarte, D., Nex, F., Kerle, N., Vosselman, G., 2018. Multi-Resolution Feature Fusion for Image Classification of Building Damages with Convolutional Neural Networks Remote Sens, 10(1636), 10-3390.
8. Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., Omata, H., 2018. Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone. arXiv preprint arXiv:1801.09454.
9. Wang, N., Zhao, Q., Li, S., Zhao, X., Zhao, P., 2018. Damage Classification for Masonry Historic Structures Using Convolutional Neural Networks Based on Still Images. Computer-Aided Civil and Infrastructure Engineering, 33(12), 1073-1089.
10. Reddy, A., Indragandhi, V., Ravi, L., Subramaniaswamy, V., 2019. Detection of Cracks and Damage in Wind Turbine Blades Using Artificial Intelligence-Based Image Analytics. Measurement, 147, 106823.
11. Shihavuddin, A.S.M., Rashid, M.R.A., Maruf, M.H., Hasan, M.A., ul Haq, M.A., Ashique, R. H., Al Mansur, A., 2021. Image Based Surface Damage Detection of Renewable Energy Installations Using a Unified Deep Learning Approach. Energy Reports, 7, 4566-4576.
12. Choi, K.Y., Kim, S.S., 2005. Morphological Analysis and Classification of Types of Surface Corrosion Damage by Digital Image Processing. Corrosion Science, 47(1), 1-15.
13. Surface Crack Detection Using DL Models, Veri seti: <https://www.kaggle.com/hanzamanssor/surface-crack-detection-using-dl-models/data>, Erişim tarihi: 28.12.2021.
14. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T., 2018. Recent Advances in Convolutional Neural Networks. Pattern Recognition, 77, 354-377.
15. Min, S., Lee, B., Yoon, S., 2017. Deep Learning in Bioinformatics. Briefings in Bioinformatics, 18(5), 851-869.
16. Hanbay, K., 2020. Hyperspectral Image Classification Using Convolutional Neural Network and Two-Dimensional Complex Gabor Transform. Journal of the Faculty of Engineering and Architecture of Gazi University, 35(1), 443-456.
17. Niepert, M., Ahmed, M., Kutzkov, K., 2014. Learning Convolutional Neural Networks for Graphs. In International Conference on Machine Learning, Germany: 2016. 2014-2023.
18. Kumar, R., 2020. Adding Binary Search Connections to Improve Densenet Performance. In 5th International Conference on Next Generation Computing Technologies (NGCT-2019).
19. Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., 2017. Densely Connected Convolutional Networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 4700-4708.

20. Li, X., Shen, X., Zhou, Y., Wang, X., Li, T.Q., 2020. Classification of Breast Cancer Histopathological Images Using Interleaved DenseNet with SENet (IDSNet). PloS one, 15(5), e0232127.
21. Toğaçar, M., Ergen, B., Özyurt, F., 2020. Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 32(1), 47-56.
22. Mateen, M., Wen, J., Song, S., Huang, Z., 2018. Fundus Image Classification Using VGG-19 Architecture with PCA and SVD. Symmetry, 11(1), 1.
23. Lin, M., Chen, Q., Yan, S., 2014. Network in Network, 2nd Int. Conf. Learn. Represent. ICLR 2014 - Conf. Track Proc.
24. 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, 2818-2826.
25. Chollet, F., 2017. Xception: Deep Learning with Depthwise Separable Convolutions. in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1251-1258.
26. Söylemez, Ö.F., Ergen, B., 2020. Farklı Evrişimsel Sinir Ağı Mimarilerinin Yüz İfade Analizi Alanındaki Başarımlarının İncelenmesi. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 11(1), 123-133.
27. Fan, Z., Wu, Y., Lu, J., Li, W., 2018. Automatic Pavement Crack Detection Based on Structured Prediction with the Convolutional Neural Network. arXiv preprint arXiv:1802.02208.

