

İHA GÖRÜNTÜLERİNDEN KONVOLÜSYONEL SİNİR AĞLARI İLE BİNA HASAR TESPİTİ

Gökçe Yağmur BUDAK¹, Meryem Sıla DOĞAN², Saygın ABDİKAN³

¹Müh., Hacettepe Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, 06800, Çankaya, Ankara, gokcebudak51@gmail.com

²Müh., Hacettepe Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, 06800, Çankaya, Ankara, msiladogan99@gmail.com

³Doç. Dr., Hacettepe Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, 06800, Çankaya, Ankara, sayginabdikan@hacettepe.edu.tr

ÖZET

20. yüzyılın sonlarından itibaren dünyadaki doğal afetlerin sayısında hızlı artışlar gözlemlenmiştir. Özellikle afetlerin binalara verdiği zararlar insanların yaşamları üzerinde büyük bir etkiye sahiptir. Şiddetli hava koşullarına sahip ve doğal afet meydana gelmiş alanlarda güç kaynağının tükenmiş olması, alt yapının bozulması gibi nedenlerden dolayı erişim zorlaşmaktadır. Bu nedenle hasar gören alan hakkında bilgi toplayabilmek ve hasar tespiti yapabilmek için uzaktan algılama ve analiz teknikleri geliştirilmiştir. Bu teknikler, hasarlı binaların tespit edilmesi ve acil müdahalenin hızlı bir şekilde başlatılmasından dolayı büyük önem taşımaktadır. Bu çalışma, 6 Eylül 2017 tarihinde Sint Maarten adasında meydana gelen Irma Kasırgası'nın neden olduğu hasarı uzaktan algılama yöntemleriyle tespit etmeyi amaçlamaktadır. Doğal afetin meydana geldiği bölgenin RescUAV Programından elde edilen çok yüksek çözünürlüklü İHA görüntüleri kullanılarak hasar tespitinde en iyi sonuçları veren uzaktan algılama tekniği belirlenmiştir. İHA görüntüleri ve Copernicus platformundan sağlanan referans veriler kullanılarak çalışma alanının verileri hazırlanmış ve ardından Konvolüsyonel Sinir Ağları (KSA) kullanılarak ilgili alandaki binalar hasar derecelerine göre sınıflandırılmıştır. Derin Öğrenme yöntemlerinden biri olan KSA yapısı kullanıldığı için sınıflandırma yüksek performans ve doğruluk sağlamıştır.

Anahtar Sözcükler: İHA, konvolüsyonel sinir ağları, bina hasar tespiti

ABSTRACT

BUILDING DAMAGE DETECTION WITH CONVOLUTIONAL NEURAL NETWORKS FROM UAV IMAGES

Since the end of the 20th century, rapid increases have been observed in the number of natural disasters in the world. Especially the damage caused by disasters to buildings has a great impact on people's lives. Areas with severe weather conditions and natural disasters will be difficult to access due to reasons such as depletion of power supply in the areas and deterioration of infrastructure. For this reason, remote sensing and analysis techniques have been developed to collect information about the damaged area and to detect damage. These techniques are of great importance as damaged buildings can be detected and emergency response can be initiated quickly. This study aims to detect the damage caused by Hurricane Irma, which occurred on the island of Sint Maarten on September 6, 2017, using remote sensing methods. The remote sensing technique, which gives the best results in damage detection, was determined by using very high resolution UAV images obtained from the RescUAV Program of the region where the natural disaster occurred. The data of the study area were prepared using UAV images and reference data from the Copernicus platform, and then the buildings in the relevant area were classified according to their degree of damage using Convolutional Neural Networks (CNN). Classification has provided high performance and accuracy since CNN structure, which is one of the Deep Learning methods, is used.

Keywords: UAV, convolutional neural networks, building damage detection

1. GİRİŞ

Doğal afetler, canlıları doğrudan tehdit eden ve tamamen doğal nedenlerle meydana gelen afetlere verilen isimdir. Doğal afetlerin önlenmesi, tespiti ve meydana geldikten sonra canlıların korunması için birçok akademik ve sosyal çalışma yapılmaktadır. 31 doğal afet türünden 28'i meteorolojik afetlerdir. Meteorolojik/klimatik afetlerden biri olan ve 2017 yılında Karayipler'de meydana gelen Irma Kasırgası, geçtiğimiz yüzyılın en büyük felaketlerinden biridir. Bu felaket, çevresindeki birçok adaya zarar verdiği gibi insan hayatını da olumsuz etkilemiştir. Hollanda Krallığı'nı oluşturan dört ülkeden biri olan Sint Maarten'de, 6 Eylül tarihinde rüzgarın saatte 185 mil hıza ulaştığı bir kasırga meydana gelmiştir (Wilts, 2017). Dünya çapında birçok sivil toplum kuruluşu yaşanan afetin etkisini azaltmayı amaçlamıştır. Afet Risk Yönetimi de bu amaca hizmet etmektedir. Son yıllarda hem uzayda (optik ve Sentetik Açıklıklı Radar (SAR)) hem de atmosferde (hava ve İnsansız Hava Aracı (İHA) tabanlı) geliştirilen uzaktan algılama tekniklerinin Afet Risk Yönetimi için güvenilir bir yöntem olduğu kanıtlanmıştır. Uzaktan algılama teknikleri, afet nedeniyle oluşan hasarların hızlı tespiti için daha etkin bir müdahale sağlamaktadır. İncelenen birçok hasar tespit çalışmasında farklı yaklaşımlar geliştirilmiştir. Bunlar arasında sınıflandırma teknikleri, görüntü farkı metodu, segmentasyon ve değişiklik tespit yöntemleri bu çalışmalarda sıklıkla kullanılan yöntemler arasındadır. Yapılan çalışmada, kasırgadan etkilenen bölgenin İHA görüntüleri kullanılarak en iyi sonuçları veren sınıflandırma yöntemi araştırılmıştır. Literatüre göre Konvolüsyonel Sinir Ağı, sınıflandırma için yüksek doğruluk sağlayan bir sinir ağı yapısıdır (Elngar vd., 2021).

Sümer ve Türker (2007) tarafından yapılan çalışmada deprem nedeniyle yıkılan binaların belirlenmesi için watershed segmentasyonu kullanılmıştır. Çalışmada, watershed segmentasyonu yöntemine dayalı bina tabanlı sistem yaklaşımı ile bir yazılım geliştirilmiştir. Oluşturulan sistem, deprem sonrası hava fotoğrafları ve mevcut deprem öncesi vektör bina sınır koordinatlarını kullanarak çöken binaları tespit etmek için hızlı ve doğru bir analiz sağlar. Segmentasyon sonucu elde edilen gölge pikselleri ile arabellek derinliğine düşen gerçek gölge pikselleri arasındaki uyum ölçülerek, binaların özelliklerine göre 'yıkılmış' veya 'tahrip edilmemiş' olarak sınıflandırılması sonucu elde edilmektedir. Bu çalışmada, deprem sonrası hava görüntüsü ve mevcut vektör bina sınır verilerinin bütünleşik analizi sonucunda, segmentasyon algoritması kullanılarak deprem nedeniyle yıkılan binaların tespitinde %80,63 başarı oranı sağlanmaktadır.

Kersbergen (2017) tarafından yapılan çalışmada, sinir ağlarının ve dolayısıyla CNN'lerin hasar tespitinde sınıflandırma çalışmaları incelenmiştir. CNN'i kullanmanın temel nedeni, yüksek sınıflandırma doğruluğudur. CNN'ler, filtreler aracılığıyla katman yapılarının oluşturulduğu ve öğrenmenin sinir ağı yapısı ile gerçekleştirildiği sistemlerdir. Veriler, binaları çevreleyen sınırlayıcı kutular tarafından belirlenen boyutlarda üretilmiştir. Veriler eğitim ve test verisi olarak ayrılmıştır (%70 eğitim, %30 test). Öğrenme oranı 0,001 olarak ayarlanmış, böylece aşırı uyum sorunu ortadan kalkmıştır. Son olarak, eğitilen ağların kaydedildiği model, daha önce kullanılmayan veriler ile sınıflandırılmıştır. Elde edilen tahminler, veriler kullanılarak gerçek değerlerle karşılaştırıldı. Hasarlı ve hasarsız olmak üzere iki sınıf için elde edilen doğruluk %76'dır.

Bu çalışmada bölgenin olay sonrası İHA görüntüleri kullanılarak derin öğrenme yöntemlerinden biri olan Konvolüsyonel Sinir Ağları uygulanmıştır. Hafif hasarlı, orta hasarlı ve yüksek/tamamen hasarlı olmak üzere üç sınıf için nesne tabanlı bir sınıflandırma tekniği uygulanmıştır.

2. ÇALIŞMA ALANI

Bu çalışmada hazırlanan verilerle CNN mimarilerinin kullanılması uygun bulunmuştur. Açık kaynaklı uydu görüntüsü ve İHA görüntüsü sağlayan Open Aerial Map ¹ platformundan ilgili bölge için olay öncesi uydu görüntüsü ve olay sonrası İHA görüntüleri elde edilmiştir. Böylece hasarlı alanlar kullanıcı tarafından tespit edilebilmektedir. Bu çalışmada, doğal afetlerden biri olan kasırga sonrası binalarda meydana gelen hasarların doğru bir şekilde sınıflandırılmasının yolları araştırılmıştır. Mevcut literatürdeki yöntemlere dayanarak, çalışma alanından elde edilen verilerin doğruluğu gerçek dünya verileriyle değerlendirilerek test edilmektedir.

Bu çalışma, 6 Eylül 2017 tarihinde Sint Maarten adasında meydana gelen Irma Kasırgası'nın sebep olduğu bina hasarını ve bu binaların hasar derecelerini uzaktan algılama yöntemleriyle tespit etmeyi amaçlamaktadır (Kersbergen, 2017). Çalışma alanı olarak belirlenen Sint Maarten adası Hollanda Krallığı'na aittir ve Karayip Denizi'nde yer almaktadır. Çalışmada, kasırgadan etkilenen bölgenin olay sonrası İHA görüntüleri kullanılarak hasar tespitinde derin öğrenme yöntemlerinden biri olan Konvolüsyonel Sinir Ağları (CNN) uygulanmaktadır (Vetrivel vd., 2016). Elde edilen 4 cm çözünürlüklü GlobalMedic'in RescUAV Programı tarafından üretilen İHA görüntülerin yerine 8 cm çözünürlüklü görüntülerin kullanılması için görüntüler yeniden örneklendirilmiştir. Bina hasar tespit sürecinin doğruluk kontrolünde, çalışma alanına ait Copernicus² ve MAXAR³ platformundan sağlanan vektör referans verileri ve olay sonrası WorldView-2 uydu görüntüleri kullanılmaktadır.



Şekil 1. Sint Maarten Adası'nın Konumu


3. YÖNTEM

Yapılan çalışmada ilgili alanın olay sonrası İHA görüntüsü ve bina poligonlarını içeren vektör verisi kullanılmıştır. Kullanılan referans vektör verilerinde binaların hasar derece sınıfları bulunmaktadır. Elde edilen vektör verilerden her bina için sahne çıkarımı yapılarak ve hasar büyüklüğüne göre gruplandırılmıştır. Verilerin hasar dereceleri hafif hasarlı, orta hasarlı ve yüksek/tamamen hasarlı olmak üzere üç grup halinde sınıflara ayrılmıştır. Veriler modele yerleştirilmeden önce ön işleme yapılmıştır. Daha sonra ayrılan sınıflar test ve eğitim grupları olarak Convolutional Neural Network (CNN) içerisinde sınıflandırılmıştır. Test verileri ile eğitilmiş model kullanılarak doğruluk analizi yapılmıştır.

¹ <https://openaerialmap.org>

² <https://emergency.copernicus.eu>

³ <https://www.maxar.com>



Şekil 2. Metodolojik çerçevenin şematik diyagramı

Şekil 2'de gösterilen şematik diyagram üç aşamaya ayrılmıştır. İlk aşama olan veri hazırlama kısmında, bina sahneleri tanımlanır, veri setleri kategorize edilir ve görüntülere ön işleme yapılır. İkinci aşama olan sınıflandırmada ise kırılan görüntüler eğitim, doğrulama ve test veri setleri olarak ayrılır, oluşturulan sınıfların veri sayısının eşit veya eşit miktara yakın olmasına dikkat edilir. Bazı sınıflar için veri miktarının yeterli olmadığı durumlarda veri artırma işlemi yapılır ve bu şekilde model her sınıf için eşit miktarda veri ile eğitilmiş olur. Eğitilecek veri modeli yaratılan CNN mimarileridir ve giriş verileri eğitim sınıfıdır. Son aşamada ise modelin doğruluğu test verileri ile kontrol edilir. Model yeterli doğruluğa veya maksimum yinelemeye ulaşmazsa, CNN modelindeki hiper parametreler, filtre veya katman sayısı değiştirilerek model yeniden eğitilir. Model yeterli doğruluğa ulaştığında doğruluk, kesinlik, F1-puanı ve geri çağırma gibi doğruluk parametreleri ile analiz edilir.

3.1 Veri Hazırlama


Binaların hasar derecelerine göre sınıflandırılan veriler CNN modelinde kullanılmak üzere QGIS platformunda hazırlanmaktadır. Veriler hazırlanırken Copernicus programının Irma kasırgası için hazırladığı Sint Maarten Adası'nın olay öncesi uydu görüntüsü ve bina hasar etiketleri referans alınmaktadır. Verilerin hazırlanma adımları aşağıdaki gibidir:

I. Her hasar sınıfı için ayrı vektör dosyaları oluşturulmuş, nokta geometri tipi seçilmiştir. Hasar sınıfları şu şekildedir: hafif hasarlı, orta hasarlı ve yüksek/tamamen hasarlı (Şekil 3). Copernicus verileri referans alınarak bina çatılarının orta noktalarına noktalar atanmaktadır.

II. Daha sonra QGIS buffer aracı kullanılarak bu noktalara kare tamponlar eklenmiştir. Binalar için uygun bulunan tamponun kenar uzunluğu 9 m olarak belirlendi. Elde edilen tamponlar poligon geometri tipi olarak kaydedilmiştir (Şekil 4).

III. QGIS'te maske katmanına göre klip tarama aracı kullanılarak, raster görüntüdeki binalar iteratif bir şekilde kırılmış ve kaydedilmiştir.

IV. Hazırlanan verilerin sınıf doğruluğu ve modelde kullanılabilirliği kontrol edilmiştir. Hafif hasarlı sınıf, hasarsız veya ihmal edilebilir hasarlı binaları içermektedir. Binaların çatılarının yarısından daha az bir kısmı hasarlı ise binalar orta hasarlı sınıftadır. Bina çatılarının yarısından fazlası hasarlı ise veya bina tamamen yıkılmışsa binalar yüksek/tamamen hasarlı sınıfta atanmıştır.



Şekil 3. Hasar sınıfları. (a) hafif hasarlı; (b) orta hasarlı; (c) yüksek/tamamen hasarlı.



Şekil 4. Noktaların ve tampon alanların binalar üzerindeki görünümü

Copernicus programından alınan vektör verilerin hasar dereceleri beş sınıftan oluşmaktadır. Veri sayısının yetersiz olması, sınıflardaki verilerin dengesiz dağılımı, yanlış referans etiketleri gibi sorunlar nedeniyle sınıf sayısı üçe düşürülmüştür. Hafif hasarlı sınıf, hasarsız bina verileri ile ihmal edilebilir hasarlı bina verileri birleştirilerek oluşturulmuştur. Yüksek hasarlı ve tamamen hasarlı sınıflar birleştirilerek yüksek/tamamen hasarlı sınıf elde edilmiştir. Böylece modelden üç sınıf için sonuç elde edilmiştir.

3.2 CNN Modelinin Hazırlanması


Çalışmada makine öğrenmesi uygulamalarında kullanılan TensorFlow çerçevesi python programlama dilinde kullanılmaktadır. TensorFlow içerisinde çalışan Keras kütüphanesi de bu çalışmada yer almaktadır. Çalışma ortamı Google Collab olarak belirlenmiştir. Bu sayede kütüphanelerin ve çerçevelerin bilgisayar belleğinde yer kaplamaması sağlanır. Hazırlanan veriler Google Drive’da saklanmaktadır. Bu projede bina hasar tespiti için 2 model kullanılmaktadır. İlk model bu çalışma kapsamında hazırlanmıştır. İkinci model ise dünya genelinde sınıflandırma ve tespit çalışmalarında sıklıkla kullanılan VGG-16 mimarisidir. İki modelde de görüntü girişi boyutu 128x128 pikseldir. Bu iki modelin eğitim, doğrulama ve test doğrulukları karşılaştırılmış ve değerlendirilmiştir. Ek olarak, her sınıftan 1000’er adet olmak üzere toplam veri sayısı 3000 adettir. Bu verilerin 2700 adeti eğitim için, 300 adeti test için kullanılmaktadır.

Konvolüsyonel sinir ağlarını tanımlamak gerekirse, giriş katmanı CNN'nin ilk katmanıdır. Bu katmanda veriler hamdır ve hem ağ başarısı hem de derinlik ve donanım maliyeti için katmandaki verilerin boyutu seçilmelidir. CNN'nin temelini oluşturan katman konvolüsyon katmanıdır. Filtreler bu katmanda tanımlanır ve bu filtreler farklı boyutlarda kullanılabilir. Bu işlem sonucunda aktivasyon haritası oluşturulur ve her filtre için filtreye özgün özellikler görülebilir. Filtrelerin, öğrenme devam ettikçe her yinelemede değişen katsayıları vardır. Bu sayede hangi bölgelerin önemli olduğu belirlenerek özellikler bulunabilir. Konvolüsyon katmanının bir parametresi olan adım parametresi, görüntü üzerinde kaydırma gerçekleştirir. Üç kanalın (RGB) tamamında filtreleme yapıldıktan sonra, üçünün toplamı aktivasyon haritasını oluşturur. Aktivasyon fonksiyonları, oluşturulan aktivasyon haritasına doğrusal olmayan bir yapı sağlamak için kullanılır. Bu çalışmada kullanılacak ReLu aktivasyon fonksiyonunda çıkarılan özneliliklerden pozitif değerler bir sonraki katmana geçebilirken, negatif değerler sıfır olarak atanmıştır. Bu katman ile ağ daha hızlı öğrenme sağlar. Daha sonra gereksiz bilgi kullanımının önüne geçildiği ve girdi boyutunun (genişlik*yükseklik) küçültüldüğü maksimum havuzlama katmanına geçiş yapılır. Boyutu küçültmek bilgi kaybına neden olur, ancak bu işlem iki nedenden dolayı avantajlıdır. Bahsedilen durumlardan ilki hesaplama maliyetindeki azalmadır. İkincisi, modelin ezberlenmesini engeller. Havuzlama katmanında filtreler de uygulanır. Bu filtrelerde, atanan adım değerine göre kaydırma yapılır. Piksellerin maksimum değerlerinin alındığı yöntemle maksimum havuzlama denir ve bu çalışmada bu yöntem uygulanmıştır. Üst düzey özneliliklerin çıkarılmasından sonra tam bağlantılı katmana geçiş yapılır. Bu katman, önceki katmanın tüm alanlarına bağlıdır ve tek boyutludur. Ağı ezberlenme olasılığı nedeniyle tam bağlı katmandan bırakma katmanına geçiş yapılır. Bu katmanda ağı ezberlemesi engellenir. Bırakma katmanından SoftMax veya Sigmoid katmanına verinin geçişi ile verilerin 0-1 aralığındaki değerlere sahip olmasına göre hangi sınıfa ait olduklarının olasılığı hesaplanır ve veriler sınıflara atanır (İnik ve Ülker, 2017).


CNN modelinin eğitimindeki ilk adım, CNN modelinin oluşturulmasıdır. Model içeriği, konvolüsyon katmanlarının, havuzlama katmanlarının, tam bağlı katmanların sayısı ve sınıflandırma (SoftMax veya Sigmoid) katmanı olarak belirlenir. Bu katmanların sırası ve sayısı geliştiriciye özeldir. Daha sonra modelin içeriğindeki katmanların başlangıç değişkenleri tanımlanır. Bu değişkenler genel olarak filtre boyutları, filtre sayısı ve adım kaydırma miktarı olarak sıralanabilir. Daha sonra eğitim veri setinden bir girdi görüntüsü bu modele verilir ve görüntü, bir sonuç değeri ortaya çıkarmak için katmanlardan geçer. Bu aşamaya ileri besleme denir. İleri beslemede, her katmandaki her filtrenin ağırlıkları piksel değerleriyle çarpılıp toplanarak görüntü bir sonraki katmana aktarılır. Toplam hata değeri, oluşturulan ağ tarafından üretilen tahmin sonuçları ile gerçekleşen sonuçlar arasındaki fark alınarak hesaplanır. Elde edilen hata değeri ağıdaki tüm ağırlıklara dağıtılmalıdır ve bunun için bir geri yayılım algoritması kullanılır. Geri yayılım algoritmasında kullanılan her bir ağırlığın toplam hata üzerindeki etkisini hesaplamak için Stokastik Gradyan İniş optimizasyon algoritması kullanılır. Buradaki ağırlıklar güncellenerek ağı çıkışındaki toplam hata değeri azaltılır. Bu durum sınıflandırma doğruluğunu artırmaktadır. Daha sonra bu model girdi katmanındaki farklı eğitim verileri üzerinde rastgele görüntülenir, model eğitilir ve işlem tekrarlanır (Ci vd., 2019). CNN modelinde ağırlıkları güncellemek için gradyan tabanlı optimizasyon algoritmaları kullanılmaktadır. Geri yayılım algoritmasında her bir ağırlığın değeri gradyan iniş yöntemine göre hesaplanır, kısmi türev kullanılarak zincir kuralı ile hesaplamalar yapılır (İnik ve Ülker, 2017). Eğitim verileriyle oluşturulan eğitim modelinin doğruluğu test verileri kullanılarak elde edilir. Test verileri modele gösterilerek etiket değerlerinin gerçek değerlerle doğruluğu kontrol edilir. Hata (confusion) matrisi gösterimi ile her bir sınıfın gerçek ve tahmin edilen değerlerinin doğruluğu görüntülenebilir. Doğruluk, doğruluk kriterleri olan geri çağırma, f-1 puanı, doğruluk ve kesinlik kullanılarak elde edilebilir.

Bu çalışmada hazırlanan CNN mimarisinde 3 adet konvolüsyonel ağ katmanı, 3 adet maksimum havuzlama katmanı ve 1 adet tam bağlantılı katman bulunmaktadır. Bu mimaride yığın normalleştirme tekniği de kullanılmaktadır. Eğitim esnasında her katman hatasını düzeltmeye çalışır. Ancak, katmanlar toplu olarak hareket etmezler. Örneğin 1.katmanın çıktısı ile 2.katman beslenir. Herhangi bir katmandaki parametre değişikliği sonraki katmanlarda da değişime sebep olur. Giriş katmanlarındaki bu kaymalar nedeniyle eğitim süresi gittikçe artar. Bu kaymaları azaltmak için yığın normalleştirme uygulanır. Normalizasyon işlemi; tüm girdi değer dağılımlarının ortalamasını sıfır, standart sapmasını 1 olacak şekilde uygular. Dolayısıyla girdi değerleri -1 ile 1 arasına sıkıştırılmış olur. Yığın normalleştirme sayesinde ağıdaki katmanlar, önceki katmanın öğrenmesini beklemek zorunda kalmaz ve eş zamanlı olarak öğrenime olanak

sağlar. Eğitimin hızlanmasında yardımcı bir işlemdir. Proje üyeleri tarafından oluşturulan modelin mimarisi Şekil 5'te gösterilmektedir. VGG-16, 13 adet konvolüsyonel ağ katmanı, 5 adet havuz katmanı ve 1 adet küresel ortalama havuz katmanından oluşan bir CNN mimarisidir (Şekil 6). VGG-16 modelinde transfer öğrenme işlemi gerçekleştirilmiştir. Transfer öğrenme türlerinden biri olan ince ayar (fine tuning) kullanılmaktadır.




Şekil 5. Proje üyeleri tarafından oluşturulan CNN mimarisi




Şekil 6. VGG-16 mimarisi

4. SONUÇLAR

CNN mimarisi kullanılarak yapılan bina hasar tespit çalışmasında iki CNN modeli tarafından doğruluk sonuçları elde edilmiştir. Bu çalışma ile hazırlanan modelin sonuçlarına göre %84,53 eğitim doğruluğu ve %83 test doğruluğu elde edilmiştir (Şekil 7). Öğrenme aktarımı yapılan VGG-16 modelinin eğitim ve test doğruluğu için ince ayar (fine-tuning) öncesi ve sonrası olmak üzere iki sonuç elde edilmiştir. İnce ayar öncesi eğitim doğruluğu %74,58, test doğruluğu %78'dir. İnce ayar sonrası, hem eğitim hem de test doğruluğu artmaktadır, eğitim doğruluğu %83,15 ve test doğruluğu %84'tür (Şekil 8). Her iki modelin ağırlıkları, bina hasar tespiti için gelecek çalışmalarda kullanılmak üzere kaydedilmektedir. İki modelde de yüksek/tamamen hasarlı ve hafif hasarlı binaların tespitinde yüksek doğrulukta sonuç elde edilmiştir. VGG-16 modelinde en iyi uyum sağlanmıştır.




Şekil 7. Bu çalışmada oluşturulan CNN modelinin doğruluk ve hata grafikleri




Şekil 8. VGG 16 CNN modelinin doğruluk ve hata grafikleri

Şekil 9 ve 10'da CNN modellerinin hata matrisleri yer almaktadır.



Şekil 9. Proje üyeleri tarafından oluşturulan CNN modelinin hata matrisi



Şekil 10. VGG-16 CNN modelinin hata matrisi

Her iki modelde de orta dereceli hasar sınıfı, hafif hasarlı sınıf olarak tahmin edilmiştir, ancak orta hasarlı sınıf bu çalışmada önerilen modelde daha yüksek doğrulukla belirlenmiştir. VGG-16 modelinde hafif hasarlı sınıf daha yüksek doğrulukla tespit edilmiştir. Tamamen hasarlı sınıf ve hafif hasarlı sınıf her iki modelde de yüksek doğrulukta sonuçlar vermiştir. Orta derecede hasarlı sınıf diğer sınıflara göre daha düşük doğruluk vermiştir çünkü görüntülerin yeniden örneklendirilmesi nedeniyle ayrıntılar ve bilgiler kaybolmaktadır, bu sınıfa ait verileri eğtmek için yeterli veri yoktur ve verilerdeki hasar çeşitliliği yüksektir. Veriler hazırlanırken binaların ve bina çevrelerinin fiziksel özelliklerinden dolayı veri sayısını ve doğruluğu düşüren bazı sorunlarla karşılaşıldı. Kasırga sonrası mavi muşamba kaplı binalardan, hasar derecesi farklı bitişik binalardan, tampon boyutunu aşan geniş yüzeyli binalardan ve beton çatılı binalardan hasar derecesi tespiti için veri toplanamamıştır. Güneş paneline sahip binaların az sayıda olması modelin eğitimi için yeterli bulunmadığından, bu binalardan da veri toplanamamıştır.

Son zamanlarda uzaktan algılama teknikleri kullanılarak yapılan çalışmalarda uydu görüntülerinin uzamsal çözünürlüğünün artması sonucu çalışmalarda piksel tabanlı sınıflandırma yerine nesne tabanlı sınıflandırma etkin bir şekilde kullanılmaya başlanmıştır (Sabuncu ve Sunar, 2017). Piksel tabanlı sınıflandırma, yalnızca piksellerin istatistiksel analizine dayanır. Nesne tabanlı sınıflandırmada pikseller segmentasyon aşamasında gruplandırılır ve segmentlerin renk, frekans ve komşuluk gibi birçok özelliği kullanılarak tematik sınıf için daha anlamlı ve olumlu sonuçlar verir. Bu projede veriler sınıflandırılırken yama (patch) tabanlı sınıflandırma tekniği uygulanmıştır. Bu yöntem nesne tabanlı bir sınıflandırma tekniğidir. Yama tabanlı mimarilerde, her giriş yaması için modele yamanın merkezi pikseline bir etiket atanır. Bu yöntem, görüntünün her pikseli için bir yama oluşturulmasından dolayı verimsiz bir yöntem olarak kabul edilebilir (Nex, 2019). Ancak bu çalışmada uygun segmentasyon parametreleri kullanıldığından güvenilir doğruluk elde edilmiştir. Kullanılan veriler yüksek uzamsal çözünürlüğe sahip olduğundan, geleneksel piksel tabanlı sınıflandırma yaklaşımı yerine nesne tabanlı yaklaşımın kullanılması daha uygundur. Projede nesne tabanlı sınıflandırma yaklaşımı ile yüksek bir doğruluk elde edildiği açıkça görülmektedir. Sınıflandırma yönteminin başarısının büyük ölçüde uydu verilerinin ayrıntılı bilgisine ve çalışma alanının özelliklerine bağlı olduğunu belirtmek büyük önem taşımaktadır. Bina hasar tespit çalışmasına benzer önceki çalışmalar incelenmiştir. Vetrivel ve diğerleri(2016) tarafından yapılan çalışmada optik İHA görüntüleri kullanılarak CNN modeli hasarlı ve hasarsız sınıf olmak üzere iki sınıf tipi ile sınıflandırma yapılmıştır. Kullanılan modelde giriş görüntü boyutu 100x100 olup, kullanılan veri sayısı 5414 örnektir. Bu çalışmada elde edilen en yüksek doğruluk 90 ± 3 'tür. Kersbergen'in (2017) bu çalışmaya referansla yaptığı çalışmasında, hasarlı ve hasarsız olmak üzere iki sınıftan elde edilen doğruluk %76'dır. Ancak Kersbergen'in (2017) çalışmasında Vetrivel ve diğerleri (2016) tarafından yapılan çalışmanın aksine OpenStreetMap'te özellik oluşturma adımı ile veriler elde edilmiştir. Veri kümesi daha sonra 100x100 boyutuna yeniden ölçeklendirilmiştir.

4. ÖNERİLER

- Afet sonrası olay mahallinden otomatik olarak veri toplayabilen ve ilgili bölge için kırpmayı otomatik olarak gerçekleştirebilen bir eklenti tasarlamak ilerideki çalışmalar için birçok kolaylık sağlayacaktır.
- Bina hasar sınıflarının veri sayısı değiştirilerek çalışmanın doğruluğu yükseltilebilir.
- Bu çalışmada üretilen modelin ağırlıkları kullanılarak, meydana gelen başka afetler sonucunda acil yardımın hızlı bir şekilde başlatılması ve tespit edilmesi için ilgili bölgedeki hasarlı binaların hasar dereceleri belirlenebilir.

5. TEŞEKKÜR

Bu çalışmanın yürütülmesinde bizlere yön gösteren, desteğini esirgemeyen ve yüreklendiren sayın danışmanımız Doç. Dr. Saygın Abdikan'a sonsuz teşekkürlerimizi sunarız. Çalışmada kullandığımız uydu ve İHA görüntüleri için açık paylaşım sağlayan Copernicus, Maxar ve Open Aerial Map platformlarına teşekkür ederiz.

KAYNAKLAR

Ci, T., Liu, Z., Wang, Y., 2019, Assessment of the Degree of Building Damage Caused by Using Convolutional Neural Networks in Combination with Ordinal Regression. *Remote Sensing*, 11, 23, 2858.

Elngar, A., Arafa, M., Fathy, A., Moustafa, B., Mahmoud, O., Shaban, M. and Fawzy, N., 2021, Image Classification Based On CNN: A Survey, *Journal of Cybersecurity and Information Management*, 18-50.

İnik, Ö., Ülker, E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Journal of Scientific Research*, 85-104.

Kersbergen, D., 2018, Automated Building Damage Classification using Remotely Sensed Data Case study: Hurricane Damage on St. Maarten. Lisansüstü tezi, Delft University of Technology, Delft.

Sabuncu, A., Sunar, F., 2017, Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: VanErciş Depremi Örneği. *Doğal Afetler ve Çevre Dergisi*, 3, 1, 1-8

Sümer, E., Türker, M., 2007, Deprem Sonrası Hava Fotoğraflarından Bina Hasar Tespiti İçin Bütünleşik Bir Sistem Yaklaşımı: BİDHaS. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği IV. Teknik Sempozyumu, İstanbul, Türkiye, 05 Haziran 2007, ss.1-8

Vetrivel, A., Gerke, M., Kerle, N., Nex, F. and Vosselman, G., 2018, Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning, *ISPRS Journal of Photogrammetry and Remote Sensing*, 45-59.

Wilts, A., 2017, Irma: Category 5 hurricane flattens 'most solid buildings' on Saint Martin island. <https://www.independent.co.uk/news/world/americas/hurricane-irma-latest-saint-martin-caribbean-major-damage-flattens-buildings-tropical-storm-category-5-a7932446.html> [Erisim tarihi :31.10.2022]