



RESNET-34 DERİN ÖĞRENME ALGORİTMASI İLE DEPREM SONRASI YIKILAN YAPILARIN TESPİTİ: 6 ŞUBAT 2023 DEPREMİ, ANTAKYA ÖRNEĞİ

Firdevs GÜZEL^{1*}, Gülcan SARP¹, Kadir TEMURÇİN¹

¹Süleyman Demirel Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, Isparta, Türkiye.

Anahtar Kelimeler	Öz
<i>Derin Öğrenme, Hasar Tespiti, Deprem, Pleiades-1B, Antakya.</i>	Bu çalışma, 6 Şubat 2023 Kahramanmaraş depreminin etkilediği Hatay ilinin Antakya ve Defne ilçelerinde ResNET-34 derin öğrenme algoritmasını kullanarak deprem sırasında yıkılan ve yıkılmayan yapıların tespit edilmesini incelemiştir. Çalışmada, Pleiades-1B uydu görüntüleri ve OpenStreetMap verileri kullanılarak yapıların hasar durumları analiz edilmiştir. Derin öğrenme algoritması olarak ResNET-34 mimarisi, bu verilerle eğitilmiş ve %85 doğruluk ve %91 F1 skoru elde edilmiştir. Bu yüksek doğruluk oranı, derin öğrenme yöntemlerinin afet sonrası yapı hasar tespitinde ne denli etkili bir araç olduğunu ortaya koymuştur. Çalışmanın bulguları, derin öğrenme tekniklerinin afet sonrası hasar analizi ve yapı güvenliği değerlendirmelerinde etkin bir araç olarak kullanılabilmesini göstermiştir. Ayrıca çalışma, derin öğrenme tekniklerinin afet yönetimi ve şehir planlaması süreçlerinde etkili bir rol oynayabileceğine dair değerli bilgiler sunmuştur.

DETECTION OF COLLAPSED STRUCTURES AFTER EARTHQUAKE WITH RESNET-34 DEEP LEARNING ALGORITHM: 6 FEBRUARY 2023 EARTHQUAKE, ANTAKYA CASE

Keywords	Abstract
<i>Deep Learning, Damage Assessment, Earthquake, Pleiades-1B, Antakya.</i>	This study examined the detection of collapsed and non-collapsed structures during the earthquake in the Antakya and Defne districts of Hatay province, affected by the February 6, 2023 Kahramanmaraş earthquake, using the ResNET-34 deep learning algorithm. The damage status of the buildings was analyzed using Pleiades-1B satellite images and OpenStreetMap data. The ResNET-34 architecture was trained with these data as a deep learning algorithm and achieved an accuracy of 85% and an F1 score of 91%. This high accuracy rate demonstrated how effective deep learning methods can be as a tool for post-disaster building damage assessment. The findings of the study showed that deep learning techniques can be used as an effective tool in post-disaster damage analysis and building safety assessments. Furthermore, the study provided valuable insights into how deep learning techniques can play an effective role in disaster management and urban planning processes.

Alıntı / Cite

Güzel, F., Sarp, G., Temurçin, K., (2025). ResNET-34 Derin Öğrenme Algoritması ile Deprem Sonrası Yıkılan Yapıların Tespiti: 6 Şubat 2023 Depremi, Antakya Örneği, Mühendislik Bilimleri ve Tasarım Dergisi, 13(1), 49-63.

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process
F. Güzel / 0000-0002-3502-4745	Başvuru Tarihi / Submission Date 19.08.2024
G. Sarp / 0000-0002-5021-4918	Revizyon Tarihi / Revision Date 19.11.2024
K. Temurçin / 0000-0002-8726-3756	Kabul Tarihi / Accepted Date 27.11.2024
	Yayın Tarihi / Published Date 20.03.2025

* İlgili yazar / Corresponding author: firdevsguzel3@gmail.com, +90-246-211-4332

DETECTION OF COLLAPSED STRUCTURES AFTER EARTHQUAKE WITH RESNET-34 DEEP LEARNING ALGORITHM: 6 FEBRUARY 2023 EARTHQUAKE, ANTAKYA CASE

Firdevs GÜZEL^{1†}, Gülcan SARP¹, Kadir TEMURÇİN¹

¹ Süleyman Demirel University, Faculty of Humanities and Social Sciences, Department of Geography, Isparta, Türkiye.

Highlights

- Deep learning algorithms have been used in different areas of the scientific world with increasing momentum since the 2010s.
- Detection of earthquake damage in remotely sensed images with deep learning algorithms.
- The 2023 earthquakes that occurred in Turkey and affected 11 provinces caused many losses of life and property in Antakya.
- In the study, collapsed buildings in the Hatay-Antakya region, one of the regions most affected by the earthquake, were detected with high accuracy using deep learning algorithms.

Purpose and Scope

Türkiye is home to a geography that experiences constant earthquakes due to its active tectonics. The Kahramanmaraş earthquake, which occurred on February 6, 2023 and affected a wide area, caused many casualties and property losses. This article aims to classify collapsed and non-collapsed buildings on remote sensing images with high accuracy using the ResNET-34 deep learning architecture.

Design/methodology/approach

The method applied in the study consists of three stages. The first stage involves the acquisition and pre-processing of data required for the application of the method. For this purpose, the Pleiades-1B satellite image to be used in the study was obtained from Istanbul Technical University Satellite Communications and Remote Sensing Application and Research Center (ITU-CSCRS), and geometric and radiometric corrections were made to the satellite image. Building footprints were obtained from the OpenStreetMap website. Building databases were updated by comparing satellite imagery with OpenStreetMap. Finally, lithology data were digitised from the 1:100,000 scale DAF Atlas (Herece, 2008). In the second phase of the study, the collapsed and undestroyed buildings in the study area were classified using the ResNET-34 deep learning architecture on the basis of the preprocessed satellite images and the building footprints. In the third stage, the accuracy of the findings obtained with the ResNET-34 deep learning architecture was investigated and the results were evaluated in relation to lithological units.

Findings

In this study, in a selected sample area in Antakya and Defne districts of Hatay province affected by the Kahramanmaraş earthquake on 6 February 2023, building damage detection from PLAIDES satellite images was determined with 85% accuracy and 91% F1 score rate using ResNET-34 deep learning algorithm. The analysis results showed that ResNET-34 deep learning algorithm effectively determined damage detection from high-resolution satellite images in post-disaster damage detection. The high accuracy rate of the model supports that deep learning techniques can be used as an effective tool in post-disaster damage detection and building safety assessment. The study results showed that soil properties and construction should be considered in an integrated manner to increase the resilience of structures to earthquake risk. The analysis results showed that the collapsed buildings were largely concentrated in alluvial formations, and there was significant damage especially in the alluvial fan (Qha) and Asi River alluvium. These findings clearly demonstrated the negative impact of loose soils on the resilience of buildings.

Originality

The proposed novelty of the study is that it can detect collapsed buildings with high accuracy using deep learning techniques. This high accuracy of deep learning algorithms can be achieved by performing relevant analyses in a relatively short time. This high accuracy and speed eliminates post-disaster confusion about the priority and areas of aid to earthquake victims and provides great convenience to the authorities.

[†] Corresponding author: firdevsguzel3@gmail.com, +90-246-211-4332

1. Giriş (Introduction)

Türkiye, tektonik olarak aktif bir bölgede konumlanmakta olup, Arap Levhası ile Anadolu Levhası arasındaki etkileşim sonucu özellikle Kuzey Anadolu Fay Zonu (KAFZ) ve Doğu Anadolu Fay Zonu (DAFZ) üzerinde sık sık büyük ölçekli depremler meydana gelmektedir. Bunun yanı sıra, Batı Anadolu'da Ege Denizi'ne doğru uzanan faylar nedeniyle de bu bölgede önemli depremler yaşanmaktadır. Tüm bu faktörler, Türkiye'nin depremsellik açısından dikkatle incelenmesi gereken bir ülke olmasına neden olmaktadır. Ülkemizde yaşanan son büyük depremlere örnek olarak, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi (KRDAE) verilerine göre, 6 Şubat 2023 tarihinde yaklaşık 9 saat arayla gerçekleşen iki büyük deprem gösterilebilir. Bu depremlerin ilki, saat 01:17:32'de meydana gelen ve merkez üssü Yamacoba-Şehitkamil (Gaziantep) olan Mw 7.7 büyüklüğündeki depremdir. İkinci büyük deprem ise saat 10:24:47'de Mw 7.6 büyüklüğünde gerçekleşmiş olup, merkez üssü Ekinözü (Kahramanmaraş)'dür. (KRDAE: <http://www.koeri.boun.edu.tr/scripts/lst4.asp>). Yaşanan depremler, merkez üssü ve çevresindeki 11 ilde (Adana, Adıyaman, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş, Kilis, Malatya, Osmaniye ve Şanlıurfa) hissedilmiş, bu depremlerde 50 binden fazla insan hayatını kaybetmiş, binlerce yapı deprem anında yıkılmış, hasar görmüş ya da kullanılamaz hale gelmiştir.

Sismik aktivitelerin öngörülemezliği ve yıkıcı etkileri nedeniyle insan yaşamı üzerinde ciddi bir tehdit oluşturan depremler, sonrasında meydana gelen hasarın boyutu genellikle saha çalışmalarıyla değerlendirilmektedir (Ge vd., 2023; Jia ve Ye, 2023). Bu durum, büyük miktarda kaynak ve zaman gerektirdiğinden, doğal afetin etkilediği bölgelerde istenilen miktar ve hızda yardım ulaştırılmasını engelleyebilmektedir (Li ve Tang, 2020; Ma vd. 2020). Ancak, günümüzde Uzaktan Algılama (UA) görüntülerinin erişilebilirliği ve sayısal görüntü işleme teknolojilerindeki ilerlemeler sayesinde, uydu görüntülerinden elde edilen yüksek mekânsal çözünürlüklü bilgiler aracılığıyla saha çalışmaları önemli ölçüde kolaylaştırılmıştır. Özellikle deprem sonrasında ve erişilmesi zor alanlarda UA teknolojilerinin kullanımı, önemli hale gelmiş ve uzaktan algılama verilerinin analizi ile bina hasarı hakkında doğru bilgiler elde edebileceğini kanıtlamıştır (Sarp vd., 2014; Menderes vd., 2015 He vd., 2016). Son yıllarda yapılan çalışmalar, UA'nın makine öğrenmesi ve derin öğrenme gibi hızlı ve etkili tekniklerle desteklendiğinde, doğal afete ilişkin hasar ve etki boyutunun araştırılmasında saha çalışmalarından daha verimli sonuçlar verdiğini göstermiştir (Irwansyah vd., 2023). Özellikle, derin öğrenme tekniklerinin gelişimi ve bu teknolojinin yüksek çözünürlüklü uydu görüntüleriyle entegre bir şekilde kullanılması, doğal afetlerin etkilerini değerlendirmede ve hasar tespitinde önemli yenilikler sunmakta, büyük veri setlerinden karmaşık ilişkileri öğrenip hızlı ve doğru sınıflandırma yeteneği sayesinde afet sonrası yapı hasarlarını ve yıkım düzeylerini değerlendirme potansiyelini artırmaktadır.

Derin öğrenme, geleneksel görüntü işleme yöntemlerine kıyasla üstün performans sergileyebilen, hızla gelişen bir teknolojidir (Krizhevsky vd., 2012). Bu alandaki literatür, derin öğrenme algoritmalarının doğal afetler sonrası yıkılan binaların tespiti, sınıflandırılması ve segmentasyonu konularında etkili bir şekilde kullanılabileceğini göstermektedir. Örneğin, Moya vd. (2018), 2011 yılında gerçekleşen Doğu Japonya depreminde yıkılan binaları tespit etmek amacıyla bir denetimsiz lojistik regresyon yöntemi geliştirmiştir. Bu yöntem, çöken binaların sayısını ve konumlarını %80'in üzerinde bir genel doğrulukla hızlı bir şekilde tahmin etmiştir. Benzer şekilde, Ci vd. (2019), 2014 Ludian depreminden elde edilen hava görüntülerini kullanarak Object Recognition (OR) ile birlikte Convolutional Neural Network (Evrışimli Sinir Ağı (CNN)) uygulamış ve %77,39 genel doğruluk elde etmişlerdir. Ma vd. (2019), daha etkili algılama sonuçları elde etmek için YOLOv3 algoritmasını kullanmışlardır. Çalışmalarında Qinghai Eyaleti Yushu Tibet Özerk İl'inde 7.1 büyüklüğündeki deprem sonrası ve 2008 Wenchuan depreminden sonra Beichuan İlçesi'nden elde edilen UA görüntülerini analiz etmiş ve çöken binaların yüksek doğrulukla tespitini başarmışlardır. Moradi vd. (2020), Haiti'nin Very High Resolution (VHR) uydu görüntülerini ve U-Net konvolüsyon ağını kullanarak bina hasarını %68,71 genel doğrulukla belirlemiştir. Ji vd. (2020), 2010 Haiti depreminin öncesi ve sonrasına ait görüntülerle eğitilmiş bir Visual Geometry Group Network (VGGNet) modeli kullanarak %85,19 genel doğruluk ve %67,14 Kappa değeri elde etmişlerdir. Rashidian vd. (2021), xView veri seti ve değiştirilmiş bir U-Net kullanarak yıkılan binaları %76 ve sağlam binaları %95 doğrulukla tespit etmiş, ayrıca Google Earth görüntüleriyle Pueblo depremine dair bağımsız veri seti üzerindeki ağın performansını test etmişlerdir. Ge vd. (2023), 2010 Yushu ve 2023 Türkiye depremlerinde kendi kendini 6 saat içinde eğitebilen ve Kappa katsayısını %6,4 artıran bir model önermişlerdir. Hacıfendioğlu vd. (2024) tarafından gerçekleştirilen çalışmada ise, Türkiye'nin güney ve güneydoğusunda kullanılan uydu görüntüleri üzerinde U-Net, LinkNet, Feature Pyramid Network (FPN) ve Pyramid Scene Parsing Network (PSPNet) mimarileri kullanılarak yıkılmış binalar üzerinde derin öğrenme algoritmaları ile görüntü segmentasyonu yapılmıştır. Elde edilen sonuçlar, tüm mimarilerin %96 oranında doğruluğa ulaştığını göstermiştir. Bu bulgular, derin öğrenmenin deprem kaynaklı bina hasarının değerlendirilmesinde önemli bir araç olduğunu açıkça ortaya koymaktadır.

Bu çalışmada, 6 Şubat 2023 tarihinde meydana gelen depremden en çok etkilenen iller arasında yer alan Hatay'ın, Antakya ve Defne ilçelerinde yıkımın yoğun olarak yaşandığı bir alanda derin öğrenme algoritmasını test etmek üzere çalışma alanı olarak seçilmiştir. Seçilen alanda yıkılan ve yıkılmayan binaların sınıflandırılması için derin öğrenme mimarisi ResNET-34 kullanılarak bu mimarinin etkinliği araştırılmıştır. Çalışmada kullanılan bina ayak izleri OpenSteeMap'den elde edilmiş ve sınıflandırma için 0,5 metre çözünürlüklü Pleiades 1B uydu görüntüleri kullanılmıştır. Çalışma sonucunda yıkılan ve yıkılmayan yapıların tespitinde uygulanan yöntemin genel doğruluğu % 85 ve F1 Skor değeri %91 olarak belirlenmiştir. Çalışma sonucunda elde edilen bu doğruluk değerleri, uygulanan yöntemin büyük ölçekli afetler sonrası hasar tespitindeki önemini göstermiştir.

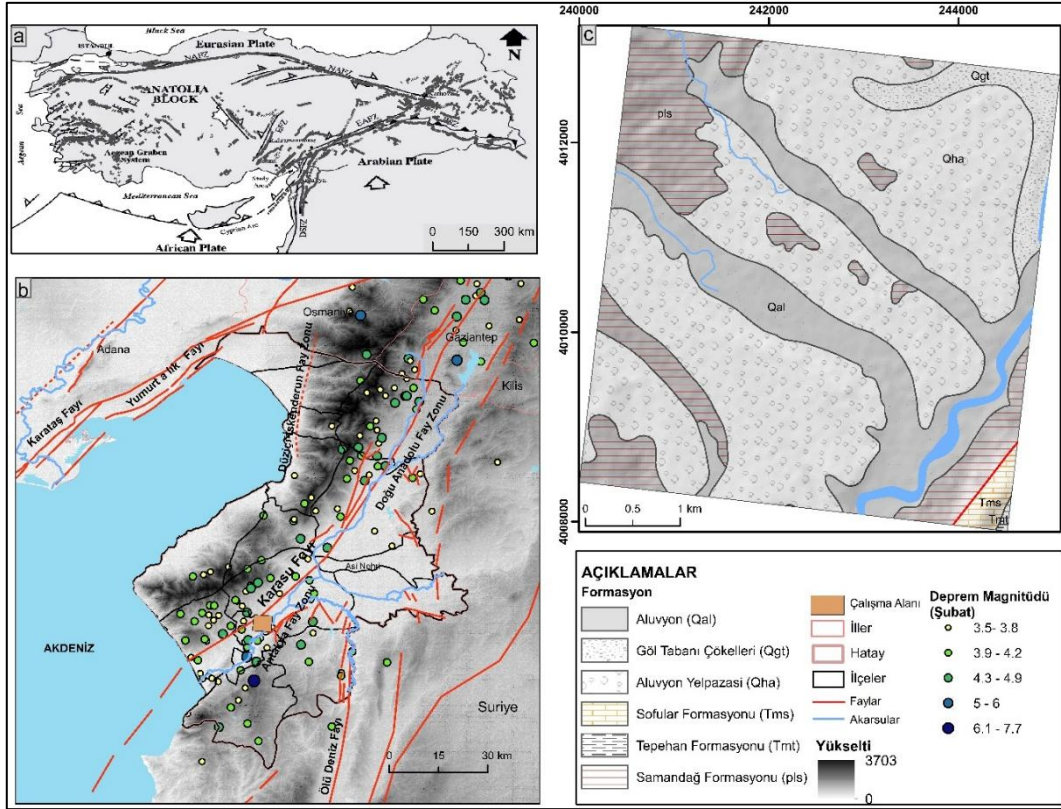
2. Çalışma Alanı (Study Area)

Hatay ili, Akdeniz Bölgesi'nin Adana Bölümü'nün doğusunda konumlanmıştır. Hatay'ın merkez ilçesi ve il nüfusunun yoğun olduğu önemli bir şehir olan Antakya, ülkemizin önemli ovalarından biri olan Amik Ovası üzerinde, Asi Nehri'nin kenarında yer almaktadır. Şehir, jeomorfolojik olarak Asi Nehri'nin doğusunda, Habibi-Neccar Dağı'nın yamacında kurulmuş, daha sonra ise düz alanlara doğru genişlemiştir. Defne ilçesi ise fiziki yapısı itibarıyla Amanos Dağları ve Kuseyr Platosu ile çevrili çöküntü ovasının güneybatısında yer almaktadır. Türkiye İstatistik Kurumu (TÜİK) verilerine göre, Defne; Antakya ve İskenderun'dan sonra, il nüfusunun toplandığı üçüncü büyük yerleşim merkezidir (TÜİK: <https://data.tuik.gov.tr/>).

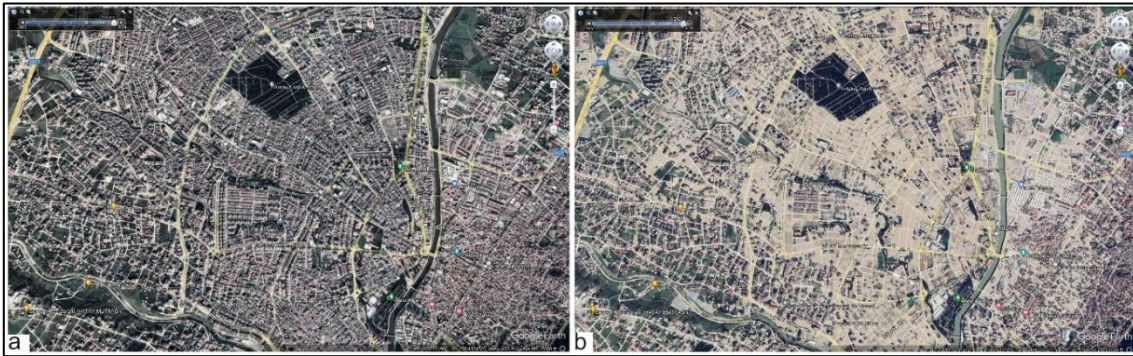
Çalışma alanı, coğrafi konumu itibarıyla çok büyük ve farklı tektonik yapıların bir arada bulunduğu ve bu yüzden de sismik aktivitenin yoğun olarak hissedildiği, Ölü Deniz Fayı, Doğu Anadolu Fayı ve Kıbrıs Yayı'nın etkisi altında gelişen Antakya-Maraş Grabeninin güneyinde yer almaktadır (Şekil 1-a). Bu bölge genel itibarıyla Avrasya, Arabistan ve Afrika levhalarının göreceli hareketlerinin etkilerini yansıtan bir konumda bulunur (Korkmaz, 2006). Bu levhalardan Afrika ve Arabistan levhalarının Anadolu levhasını sıkıştırması sonucunda bölgede birçok fay hattı gelişim göstermiştir (Şekil 1-a). Alanı etkileyen temel fayın üzerinde farklı görüşler bulunmaktadır. Örneğin, Gülen vd. (1987) ile Korkmaz, (2006) yaptıkları çalışmada alanı asıl etkileyen fayın Karasu Fayı olduğunu ifade etmişlerdir. Över vd. (2001, 2004b) ise Helen-Kıbrıs yayının bu alana kadar uzantısı olan Kıbrıs-Antakya Transform (KAT) Fayı'nın alanı etkilediğini belirtmişlerdir. Bu fayların yanı sıra şehir ve yakın çevresinde birçok irili ufaklı fayın da bulunması, Antakya şehrinin tektonik aktivitelerden önemli ölçüde etkilenmesine neden olmaktadır (Şekil 1-b).

Antakya'nın fay hatları üzerinde bulunması, bölgenin deprem riskinin yüksek olmasına neden olmaktadır. Tarih boyunca Antakya'da birçok yıkıcı deprem meydana gelmiştir. Tarihsel kayıtlara bakıldığında MÖ 65, MS 47, 115, 148, 341-42, 458, 526, 528, 551, 557, 588, 712, 848, 860, 956, 1054, 1074, 1091-92 yıllarında birçok deprem şehri etkilemiştir (Ekin, 2007; Uslu Azarak, 2023; Yüksel, 2023). Şehir, meydana gelen depremler nedeniyle birçok kez yeniden inşa edilmek zorunda kalmıştır. Bölgeyi etkileyen son büyük deprem, ülkemizde 'yüzyılın felaketi' olarak adlandırılan 6 Şubat 2023 tarihinde meydana gelen iki büyük depremdir. Kandilli Rasathanesi verilerine göre, ilk deprem Mw 7.7 büyüklüğünde olup merkez üssü Yamacoba-Şehitkamil (Gaziantep) olarak belirlenmiştir. İkinci büyük deprem ise Mw 7.6 büyüklüğünde olup merkez üssü Ekinözü (Kahramanmaraş) olarak kaydedilmiştir. Yaşanan depremler, merkez üssü ile birlikte 11 çevre ilde (Adana, Adıyaman, Diyarbakır, Elâzığ, Gaziantep, Hatay, Kahramanmaraş, Kilis, Malatya, Osmaniye ve Şanlıurfa) hissedilmiş, bu olay sonucunda birçok bina yıkılmış ve 50 binden fazla insan hayatını kaybetmiştir (TMMOB, 2023). Ayrıca, Kandilli Rasathanesi verilerine göre, şubat ayı boyunca Hatay ilinde büyüklükleri 3.5 ile 6.4 arasında değişen toplam 117 deprem meydana gelmiştir (Şekil 1-b).

Türk Tabipler Birliği (TTB)'nin 6. Ay Deprem Raporu'na göre, 2023 Kahramanmaraş depreminde Antakya'da toplam 6.369 yapının yıkıldığı, acil yıkılması gereken 3.734 yapı ve ağır hasar gören 21.830 yapı tespit edilmiştir (TTB, 2023). Şekil 2'de, çalışmada seçilen yöntemin uygulandığı örneklem alanına ait deprem öncesi (Şekil 2-a 2022 yılı aralık ayı) ve deprem sonrası (Şekil 2-b 2024 yılı mart ayı) mekânsal değişimler Google Earth'den alınan fotoğraflarla gösterilmektedir.



Şekil 2. Çalışma alanına ait deprem öncesi ve sonrası görüntü örnekleri, Google Earth'den alınmıştır (kaynak: Google Earth). (Pre-earthquake and post-earthquake image samples of the study area were taken from Google Earth (source: Google Earth))



Şekil 2. Çalışma alanına ait deprem öncesi ve sonrası görüntü örnekleri, Google Earth'den alınmıştır (kaynak: Google Earth). (Pre-earthquake and post-earthquake image samples of the study area were taken from Google Earth (source: Google Earth))

3. Materyal ve Yöntem (Material and Method)

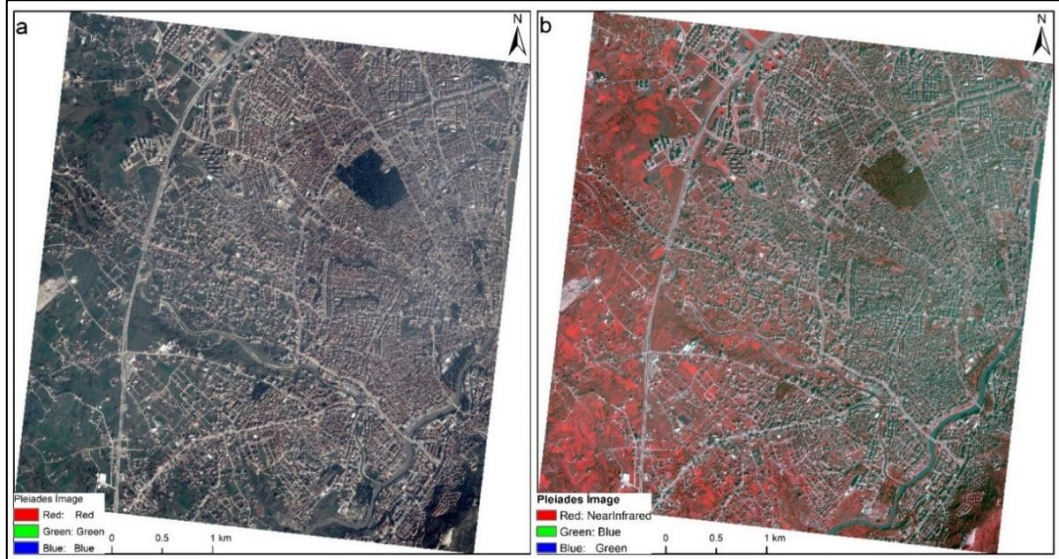
3.1 Çalışmada Kullanılan Veri Setleri ve Veri Ön düzeltmeleri (Datasets Used in The Study)

3.1.1. Pleiades-1B Uydu Görüntüsü (Pleiades-1B Satellite Image)

Çalışmada kullanılan Pleiades-1B uydusu AIRBUS Defence & Space tarafından inşa edilmiş ve 2 Aralık 2012'de başarıyla fırlatılmıştır. Uydunun bilimsel hedefleri; mühendislik ve inşaat projeleri, madencilik, endüstriyel ve askeri komplekslerin izlenmesi, çatışma bölgeleri ve kriz/felaket alanları, doğal tehlikeler, tahliye ve kurtarma operasyonları dahil olmak üzere büyük ölçekli alanların haritalanmasıdır. Yersel çözünürlüğü 0.5 metre olan

görüntülerin spektral çözünürlüğü ise 430 nm ile 950 nm arasında değişmektedir. Bu görüntüler, mavi, yeşil, kırmızı ve yakın kızılötesi bölgelerde olmak üzere toplam dört spektral bant içermektedir (Lebègue vd., 2013; Pleiades Imagery User Guide, Tablo 1).

Çalışmada kullanılan uydu görüntüsü, 8 Şubat 2023 tarihli olup, yaşanan büyük depremlerin sonrasına aittir. Uydu görüntüsünün koordinat düzlemi WGS 1984 UTM Zon 37N olup veri formatı .xml'dir. Görüntü, çalışma alanına uygun olarak kesilmiş ve veri formatı .tiff olarak dönüştürülerek analiz için hazırlanmıştır. Uydu görüntüsüne ait gerçek ve yalancı renk kombinasyonları Şekil 3 a ve b' de verilmiştir.



Şekil 3. a) Çalışma alanına ait Pleiades-1B uydu görüntüsünün gerçek renk kombinasyonu; RGB:321. b) çalışma alanına ait Pleiades-1B uydu görüntüsünün yalancı renk kombinasyonu RGB:432. (a) True colour combination of Pleiades-1B satellite image of the study area; RGB:321. b) false colour combination of Pleiades-1B satellite image of the study area; RGB:432).

Tablo 1. Pleiades-1B uydusuna ait teknik özellikler (Technical specifications of Pleiades-1B satellite)

Spektral Bantlar	Dalga Boyu Aralığı (µm)	Yersel Çözünürlük	Şerit Genişliği	Tekrar Ziyaret Zamanı
Mavi	450-530	0.5m	20km	1 gün
Kırmızı µm	510-590			
Yeşil	490-610			
Yakın Kızılötesi	750-950			

3.1.2. OpenStreetMap (OSM)

OpenStreetMap (OSM), dünya genelindeki coğrafi bilgilerin herkesin katkıda bulunabileceği ve kullanabileceği şekilde oluşturulduğu, açık ve özgür bir harita platformudur. Bu çalışmada, analiz için gerekli olan bina ayak izleri, OSM (<https://www.openstreetmap.org/>) internet adresinden ücretsiz olarak indirilen OSM verileri üzerinde çeşitli ön işlemleri gerçekleştirilerek elde edilmiş ve analizlerde kullanılmıştır.

Elde edilen bina verilerinin uydu görüntüsü ile aynı coğrafi koordinat düzlemine olmasını sağlamak amacıyla projeksiyon düzeltilmesi yapılmıştır. Projeksiyon düzeltilmesi sonucunda veri GCS_WGS_1984 koordinat düzleminden WGS_1984_UTM_Zone_37N koordinat düzlemine aktarılmıştır. Daha sonra, veri üzerinde mevcut olan coğrafik kaymalar, çift kayıtlar ve eksik binalar manuel olarak düzeltilmiş ve bina ayak izleri güncellenmiştir. Şekil 4 de görüldüğü üzere bazı binalar veri setinde eksik (Şekil 4; 1a) bazıları ise aslında mevcut olmayan binalar olarak gösterilmiştir (Şekil 4; 2a). Ayrıca, bina envanterinde bulunan binaların büyük bir kısmı gerçek mekânsal alanından sapmıştır (Şekil 4; 3a). Bu tür hatalar manuel olarak düzeltilmiş ve sonuç olarak (Şekil 4; 1b, 2b, 3b) güncellenmiş bir bina ayak izleri oluşturulmuştur. Oluşturulan bina envanteri 17.400 yapıyı içermektedir.



Şekil 4. OpenStreetMap aracılığıyla elde edilen bina ayak izleri ve hatalı olan verilerin düzenlenmesi. (Building footprints obtained through OpenStreetMap and correction of erroneous data)

3.1.3. Litoloji Verileri (Lithology Data)

Deprem sonrası yıkımın boyutlarını tam olarak anlayabilmek için bölgenin jeolojik yapısının incelenmesi kritik öneme sahiptir. Seçilen örneklem alanının jeolojik yapısı, depremin yıkıcı etkilerini doğrudan etkilemektedir. Bu doğrultuda, yıkımın boyutu ve zeminin litolojik ilişkilerini değerlendirmek amacıyla 1/100.000 ölçekli DAF Atlas (Herece, 2008). kullanılarak alanın litolojik bilgileri P36 paftasından dijital ortama aktarılıp sayısallaştırılmıştır. Buna göre örneklem alanında 6 temel birim mevcuttur. Bu birimlerden ilki, alanın yaklaşık %1.15'ini oluşturan Sofular Formasyonu (Tms)'dur. Formasyon resifal kireçtaşlarından oluşur ve ilk kez Selçuk (1985) tarafından adlandırılmıştır. Şafak (1993) tarafından belirlenen ve fosil bulgularına göre (*Praeorbulina gloerasa curva*, *Orbulina suluralis* faunasına) formasyonun yaşı Langiyen'dir. Boulton vd. (2006) ifade ettiğine göre, birim sığ deniz ortamında çökelmiştir. Bu birimin üzerinde yine ilk defa Selçuk (1985) tarafından adlandırılan Tepehan Formasyonu (Tmt-%0.12) gelir ve bu formasyon kumtaşı, killi kireçtaşı, kiltası ve marnlardan oluşmuştur. Selçuk (1985) tarafından derlenen örneklerde *Gfobigerinoides rubra* fosiline göre formasyonun yaşı Geç Miyosen 'dir. Formasyonun hangi coğrafi şartlarda çökelmiş olduğuna dair Boulton vd. (2006) birimin alt bölümü sığ, orta ve üst bölümü ise gittikçe derinleşen sığ-açık deniz ortamında çökelmiş olduğunu ifade etmişlerdir (Tablo 2, Şekil 1-c).

Alanda bulunan diğer birim Selçuk (1985) tarafından Samandağ Formasyonu (pls) olarak adlandırılan ve alanın yaklaşık %16.26'ini kaplayan formasyon kumtaşı, killi kireçtaşı ve kiltasından oluşur. Formasyonda killi kireçtaşı ara tabakaları kapsayan kumtaşları egemen kaya türüdür. Birim Hatay grabeninde ve Amik gölünün yer aldığı ovada Kuvaterner çökellerinin altında yüzyenir. Formasyonun yaşı hakkında birçok çalışma yapılmış olup genel olarak Pliyosen (Boulton vd., 2006) ile geç Pliyosen (Dubertret, 1953; Karakuş ve Taner, 1994) olarak belirlenmiştir. Elde edilen fosillere göre Pliyosen yaşında olan formasyonun alt bölümü sığ denizel, üst bölümü ise akarsu ortamında çökelmiştir.

Çalışma alanının büyük bir bölümünde ise Kuaterner'e ait alüvyal birimler bulunmaktadır. Bu birimler Alüvyon (Qal), Göl Tabanı Çökelleri (Qgt) ve Alüvyon Yelpazesi (Qha)'dir. Kuvaterner yaşlı alüvyal birimler çalışma alanının yaklaşık %82,48'ini kapsamaktadır. Bu birimler genellikle tutturulmamış, olgun ve az olgun, farklı kökenli, çakıl ve kum düzeylerinden oluşan alüvyonlar olup yer yer silt düzeyleri içermektedir. Çakıl ve kum düzeyleri yanal ve

düşey yönde geçişlidir. Nehir ve dere kenarlarında alüvyal koşullarda çökelmiş olan litolojiler olup gevşek ve zayıf zemini oluştururlar (Herece, 2008).


Tablo 2. Çalışma alanında bulunan jeolojik birimler ve yüzde dağılımları.
(Geological units in the study area and their percentage distributions)

Formasyon	Alan (km ²)	%
Tepehan Formasyonu (Tmt)	0.03	0.12
Sofular Formasyonu (Tms)	0.25	1.15
Aluyyon Yelpazesi (Qha)	12.60	57.10
Samandağ Formasyonu (pls)	3.59	16.26
Aluyyon (Qal)	4.58	20.74
Göl Tabanı Çökelleri (Qgt)	1.02	4.64

3.2. Yöntem (Method)

Çalışmada uygulanan yöntem üç aşamadan oluşmaktadır. İlk aşama, yöntemin uygulanabilmesi için gerekli verilerin temin edilmesini ve bu verilerin ön işlemlerinin yapılmasını kapsamaktadır. Bu amaçla, çalışmada kullanılacak Pleiades-1B uydu görüntüsü İstanbul Teknik Üniversitesi Uydu Haberleşmesi ve Uzaktan Algılama Uygulama ve Araştırma Merkezi'nden (İTÜ-CSCRS) temin edilmiştir ve uydu görüntüsünün geometrik ve radyometrik düzeltmeleri yapılmıştır. Bina ayak izleri, [OpenStreetMap](#) internet sitesinden alınmıştır. Uydu görüntülerinin OpenStreetMap ile karşılaştırılması yoluyla bina veri tabanları güncellenmiştir. Son olarak litoloji verisi 1/100.000 ölçekli DAF Atlas'ından dijital ortama aktarılmış ve sayısallaştırılmıştır.

Çalışmanın ikinci aşamasında, ön işlemleri tamamlanan uydu görüntüleri ve bina ayak izleri kullanılarak, ResNET-34 derin öğrenme mimarisi aracılığıyla çalışma alanındaki yıkılan ve yıkılmayan yapılar sınıflandırılmıştır. Üçüncü aşamada ise, ResNET-34 derin öğrenme mimarisi ile elde edilen bulguların doğruluk analizleri yapılmış ve sonuçlar litolojik birimlerle ilişkilendirilerek değerlendirilmiştir (Şekil 5).




Şekil 5. Uygulanan yönteme ait iş akış şeması (Flow chart of the study)

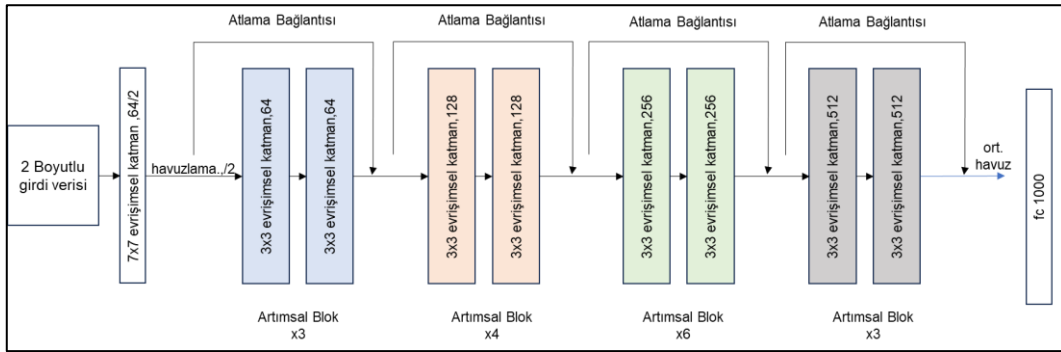
3.2.1: Derin Öğrenme Algoritması ResNET-34 Mimarisi (Deep Learning Algorithm ResNET-34 Architecture)

Derin Öğrenme (Deep Learning- DL), yapay zekanın (Artificial Intelligence- AI) bir alt kümesi olup, aynı zamanda makine öğrenmesinin (Machine Learning- ML) bir alt alanı olarak kabul edilmektedir. Hinton vd. (2006) yapmış olduğu çalışmalarla yayınlamış olduğu makalede yapay sinir ağlarına yeni bir yaklaşım getirerek, bu yaklaşımı derin öğrenme olarak adlandırılmıştır. Bu çalışma, deprem sonrası yıkılan ve yıkılmayan yapıların sınıflandırılmasını gerçekleştirmek amacıyla Derin Öğrenme yöntemlerinden biri olan ResNET-34 mimarisini kullanılmıştır. Çalışmada, ResNET-34 mimarisinin kullanılmasının amacı, büyük ölçekli veri setleri üzerinde etkili ve hassas analizler yapabile potansiyeline sahip olmasıdır. Bu mimari 2015 yılında düzenlenen ILSVRC ImageNet yarışmasında görüntü sınıflandırma alanında %3.6'lık bir hata payı ile yarışmayı kazanarak büyük bir başarı elde etmiştir. Görüntü sınıflandırmada hata payı insanlarda ortalama %5-10 oranında olurken mimarinin %3.6'lık bir hata payı ile sınıflandırmayı başarması insanlardan daha iyi bir görsel tanıma yeteneğinin olduğunu göstermiştir.

ResNet 'in temel amacı, ağlar derinleştikçe ortaya çıkan "vanishing gradient" (kaybolan gradyan) sorununu aşmak için bir çözüm sunmaktır. Bu, derin ağlarda eğitimin zorlaşmasına neden olan temel bir problemdir ve daha derin ağların performans artışından ziyade düşüşe geçmesine sebep olabilir (He vd., 2016). Kendisinden önceki mimarilerden (LeNet, AlexNet, VGGNet, GoogLeNet, ZFNet) daha fazla derinliğe sahip olan ResNet-34'ün katman sayısı diğer mimarilerden fazladır (Russakovsky, 2015; Doğan ve Türkoğlu, 2019). Bu tasarım, ağın bu katmanların girdilerine göre artık fonksiyonları öğrenmesini sağlar. ResNet, doğrudan eşlemeleri öğrenmek yerine, girdiler ve çıktılar arasındaki farkları (artıklar) öğrenerek önemli ölçüde derin ağlar için gelişmiş eğitimi kolaylaştırır (Shafik ve Gu, 2022; Tan vd., 2024). ResNet mimarisinde iki Relu (Rectified Linear Unit) ile doğrusal katman arasında bir kez kalıntı değeri (Residual Value) beslenen bir bloktan (Residual Block) oluşturulmuştur. Şekil 6' da görüldüğü üzere Residual blokta, x girişinin, konvolüsyon-ReLu-konvolüsyon serisinden sonra bir $F(x)$ sonucu vermektedir. Bu sonuç daha sonra orijinal x girişine eklenir ve $H(x) = F(x) + x$ olarak ifade edilir (He vd., 2016; İnik ve Ülker, 2017; Doğan ve Türkoğlu, 2019) (Şekil 6). Şekil 7' de ResNET-34'ün 34 katmanlı mimari yapısı görülmektedir. Böyle bir yapı ile öğrenmenin daha hızlı gelişeceği düşünülmüştür. Etkili derinlik ve eğitim verimliliği dengesi sayesinde ResNET derin öğrenmede temel bir model haline gelmiş ve bu alanda daha sonra yapılan çok sayıda yeniliğe ve çeşitliliğe ilham kaynağı olmuştur (Tan vd., 2024).




Şekil 6. Residual blok (He vd., 2016'dan değiştirilmiştir). (Residual block (Modified from He et al., 2016)).



Şekil 7. ResNet-34' e ait 34 katmanının ağ mimarisi (Zhang vd., 2023'ten değiştirilmiştir). (Network architecture of layer 34 of ResNet-34 (Modified from Zhang et al., 2023)).

4. Bulgular (Findings)

Uydu görüntüleri ve OpenStreetMap (OSM) bina verileri üzerinde ön işleme adımları uygulandıktan sonra, analiz sürecine geçilmiştir. Tüm ön işlemler ve analizler ArcGIS Pro 3.0.0 yazılımı kullanılarak gerçekleştirilmiştir. Analiz sürecinin ilk adımında, ResNET-34 derin öğrenme algoritması ile yıkılan ve yıkılmayan binaların tespitine yönelik eğitim örneklerinin toplanması ve etiketlenmesi gerçekleştirilmiştir. Bu kapsamda, çalışma alanındaki toplam 17.400 binadan 849 örnek rastlantısal bir şekilde seçilmiş ve bu örneklerden 680'i yıkılmayan binaları, 169'u ise yıkılan binaları temsil edecek şekilde etiketlenmiştir. Şekil 8'de, toplanan eğitim veri setlerinin örnekleri sunulmaktadır; bu örneklerde mavi çerçeveli binalar yıkılmayan yapıların, kırmızı çerçeveli binalar ise yıkılan yapıların temsilini göstermektedir. Etiketleme işlemi tamamlandıktan sonra, veri setleri 'Labeled Tiles' formatında metadata olarak düzenlenmiş ve her çıktı verisi belirli bir sınıfla ilişkilendirilmiştir. Bu sınıflar, nesne sınıflandırması aşamasında kullanılmak üzere hazırlanmıştır.



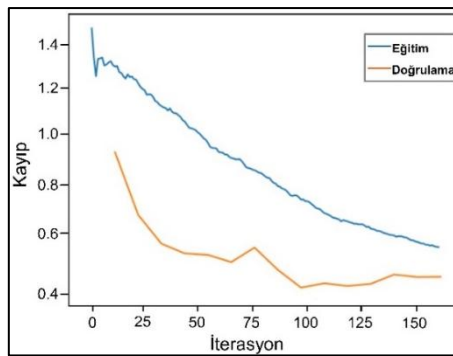
Şekil 8. Çalışma alanına ait yıkılan ve yıkılmayan binalardan alınan eğitim örnekleri.
(Educational examples taken from collapsed and non-collapsed buildings in the study area)

Derin öğrenme modelinin ihtiyaç duyduğu metadata formatında düzenlenen veriler, eğitim için hazır hale getirilmiştir. Eğitim aşamasında, nesne sınıflandırması amacıyla kullanılan model tipi Feature Classifier (Nesne Sınıflandırması) olarak belirlenmiş ve transfer öğrenme mimarisi olarak önceden yapılandırılmış ResNet-34 modeli kullanılmıştır. ResNet-34, 34 katman derinliğine sahip bir konvolüsyonel sinir ağıdır. İki eğitim sınıfı için gerçekleştirilen eğitim parametreleri detaylı olarak Tablo 3'te sunulmuştur. Tablo 3' de verilen eğitim parametrelerine göre maksimum dönem sayısı; eğitim verisinin model tarafından kaç kez taranacağını belirleyen parametredir. Yığın boyutu; modelin çalışırken her adımda ne kadar görüntü işleneceğini belirtirken, parça boyutu ise eğitim sırasında görüntülerin küçük görüntülere bölünerek işlenmesini sağlar ve böylelikle model daha esnek ve verimli bir eğitim sürecinden geçer. Doğrulama, eğitim süreci boyunca eğitim verilerinden ayrı tutulan ve modelin hiç görmediği başka bir altkümedir. Öğrenme oranı modelin her adımda ağırlıklarının ne kadar değiştirileceğini belirten bir parametre olup yüksek öğrenme oranı hızlı öğrenme sağlar fakat kararsız bir davranış gösterirken düşük öğrenme oranı ise yavaş öğrenme sağlayıp daha doğru sonuçlar elde edilmesini sağlamaktadır. Eğitim süreci boyunca kayıp fonksiyonunun değişimi, Şekil 9'de gösterilen grafik aracılığıyla görselleştirilmiştir.

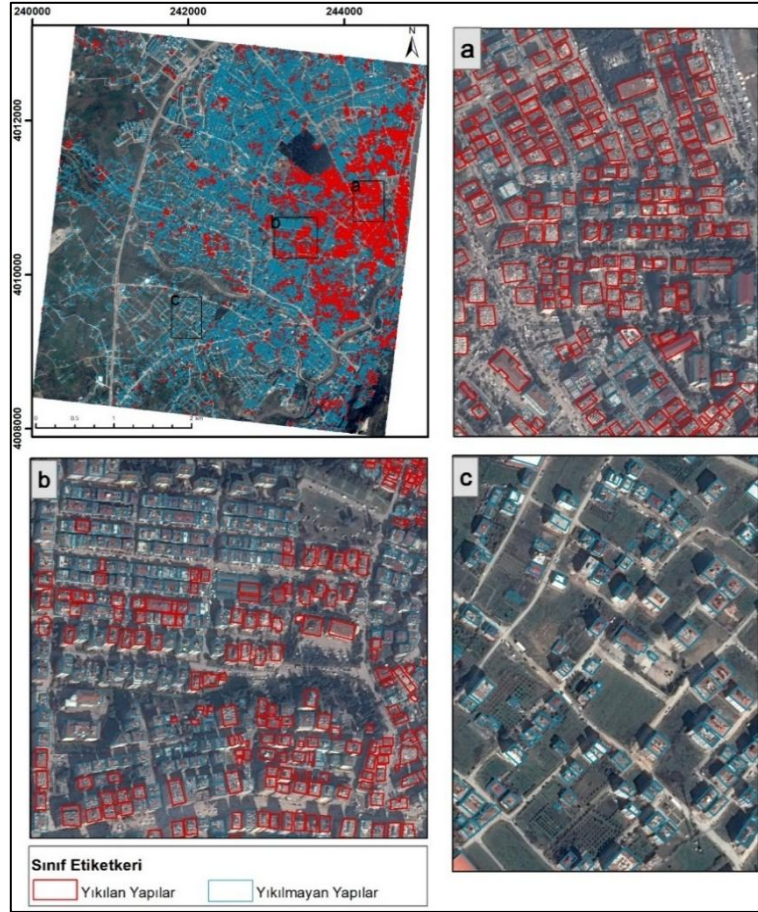
Tablo 3. Eğitilen modelin eğitim parametreleri. (Training parameters of the trained model)

Model Türü	Nesne Sınıflandırması
Maksimum Dönem Sayısı	20
Yığın Boyutu	64
Parça Boyutu	448
Doğrulama	%10
Öğrenme Oranı	8.317637711026709e-05, 0.0008317637711026709
Eğitim Süresi	10 dakika 47 saniye

Derin öğrenme algoritması, yapıların hasar durumu tespiti için belirlenen parametreler doğrultusunda eğitildikten sonra, analiz sürecinin son aşamasına geçilerek yapılar yıkılan ve yıkılmayan olarak sınıflandırılmıştır. Elde edilen bulgulara göre, çalışma alanındaki toplam 17.400 yapıdan 3.948'i yıkılmış, 13.452'si ise yıkılmamış olarak sınıflandırılmıştır. Şekil 10'da uygulanan sınıflandırma sonucunda hasarın yoğun olduğu ve yıkılan yapıların yüksek yoğunlukta bulunduğu alanlar (Şekil 10-a), orta derecede hasarın ve yıkımın gözlemlendiği alanlar (Şekil 10-b), hasarın ve yıkımın gözlemlenmediği alanlar gösterilmiştir.



Şekil 9. Eğitim boyunca oluşan kayıp fonksiyonunun grafiği. (Plot of the loss function generated during training)



Şekil 10. Derin öğrenme algoritmaları kullanılarak oluşturulan sınıflandırma analizi sonuçları; a) hasarın yoğun olduğu ve yıkılan yapıların yüksek yoğunlukta bulunduğu alanlar, b) orta derecede hasarın ve yıkımın gözlemlendiği alanlar, c) hasarın ve yıkımın gözlemlenmediği alanlar. (Classification analysis results generated using deep learning algorithms; a) areas where damage is intense and collapsed structures are in high density, b) areas where moderate damage and destruction are observed, c) areas where damage and destruction are not observed)

Analiz sonuçlarına göre, litolojik birimler ve yıkım oranları arasındaki ilişki incelendiğinde, en yüksek yıkım oranının gevşek ve dayanıksız malzemelerden oluşan Alüvyon formasyonlarında gerçekleştiği görülmüştür. Alüvyon formasyonlar içerisinde, en fazla yıkım 2.744 bina ile Alüvyon Yelpazesi (Qha) biriminde gözlemlenmiştir. Bu formasyonu, Asi Nehri tarafından biriktirilen alüvyonlar üzerinde meydana gelen 633 bina yıkımı takip etmektedir. Ayrıca, gevşek malzemelerden oluşan Göl Tabanı Çökelleri üzerinde 295 binanın yıkıldığı tespit edilmiştir. Sonuç olarak, çalışma alanının yaklaşık %82,48'ini kapsayan alüvyal formasyonlar üzerinde toplam yıkılan bina sayısı 3.672 olarak belirlenmiştir. (Tablo 4).

Tablo 4. Analiz sonuçlarına göre yıkılan ve yıkılmayan yapılar ile litolojik birimler arasındaki ilişki. (Relationship between collapsed and non-collapsed structures and geological units according to analysis results)

Formasyon	Yıkılan	Yıkılan %	Yıkılmayan	Yıkılmayan %
Tepehan Formasyonu (Tmt)	0	0	0	0
Sofular Formasyonu (Tms)	4	0.02	18	0.10
Alüvyon Yelpazesi (Qha)	2744	15.77	8587	49.35
Samandağ Formasyonu (pls)	272	1.56	1265	7.27
Alüvyon (Qal)	633	3.64	2851	16.39
Göl Tabanı Çökelleri (Qgt)	295	1.70	731	4.20

Kuvaterner yaşlı alüvyal formasyonlar çalışma alanının yaklaşık %82,48'ini kapsamakta olduğuna yukarıda değinilmiştir. Çalışma alanının da içerisinde bulunduğu Antakya ve çevresinin gevşek ve sağlam olmayan bir birim üzerine inşa edilmesi ve bu durumun ciddi kayıplara neden olabileceği daha önce araştırmacılar tarafından da vurgulanmıştır (Beyen vd., 2003; Korkmaz, 2006).

5. Doğruluk Değerlendirmeleri (Accuracy Assessments)

ResNET-34 derin öğrenme algoritmasıyla yıkılan ve yıkılmayan binaların sınıflandırılması işleminden sonra elde edilen sonuçların doğruluğu karışıklık matrisi (confusion matrix) ile hesaplanmıştır. Hesaplama sınıflandırma için kullanılan eğitim örnekleri (yer doğrulama noktaları) kullanılmıştır. ArcGIS ortamında eğitim örneklerinin üzerine 500 örnek nokta rastgele örnekleme yöntemi ile seçilmiştir. Örnek noktalar üzerinde sınıflandırma ve yer doğrulama noktaları üzerinde karışıklık matrisi hesaplanmıştır. Bu matriste Gerçek Pozitif (TP) pozitif olarak sınıflandırılan pozitif örnektir; Yanlış Negatif (FN) negatif olarak yanlış sınıflandırılan pozitif örnektir; Gerçek Negatif (TN) negatif olarak sınıflandırılan negatif örnektir; Yanlış Pozitif (FP) pozitif olarak yanlış sınıflandırılan negatif örnektir. Doğruluk değerlendirmelerinde; Özgüllük (Specificity), bir testin gerçek negatifleri doğru bir şekilde tanımlama yeteneğidir. Presicion (Kesinlik), gerçek pozitif ve yanlış pozitif örneklerinin toplamı ile temsil edilen pozitif sınıf örneklerinin toplam sayısı içinde doğru etiketlenmiş pozitif örneklerin payıdır. Recall, bir testin doğru tanımlanan pozitif sınıf örneklerinin gerçek Pozitif sınıf örneklerinin toplam sayısı içindeki payıdır ve bir testin gerçek pozitifleri doğru bir şekilde tanımlama yeteneğini ölçer. Toplam sınıflandırma Doğruluğu (Accuracy), sınıflandırıcının iki grup arasında ayırım yapma yeteneğidir. Bazı durumlarda Presicion ve Recall ölçütleri tek başlarına anlamlı bir karşılaştırma sonucu çıkarılmasında yeterli olmamaktadır. İki değeri bir arada değerlendiren F1 Skoru sayesinde daha anlamlı sonuçlar üretebilmektedir. F1 Skoru, Presicion ve Recall değerlerinin harmonik ortalaması alınarak elde edilmektedir ve hem yanlış pozitifleri hem de yanlış negatifleri hesaba kattığı için dengeli bir performans değerlendirmesi sunar (Lipton vd., 2014; Congalton ve Green, 2019; Kranjčić vd., 2019; Huang vd., 2015).

Analiz sonucunda elde edilen doğruluk değerlerine bakıldığında, bir testin gerçek pozitifleri doğru bir şekilde tanımlama yeteneğini ölçen Recall değeri %86, gerçek negatifleri doğru bir şekilde tanımlama yeteneğini ölçen Özgüllük (Specificity) değeri %77 olarak tespit edilmiştir. Bunun yanı sıra genel Doğruluk (Accuracy), %85 ve F1 Skor değeri %91 olarak tespit edilmiştir. Doğruluk hesaplamalarında kullanılan formüller ve elde edilen sonuçlar Tablo 5'de verilmiştir.

Tablo 5. Çalışmada kullanılan karışıklık matrisleri ve elde edilen sonuçlar.
(Confusion matrices used in the study and the results obtained)

	Formül	Sonuç
Özgüllük (Specificity),	$TN / (TN + FP)$	0.77
Kesinlik (Presicion)	$TP / (TP + FP)$	0.96
Recall	$TP / (TP + FN)$	0.86
Doğruluk (Accuracy)	$(TP + TN) / (TP + TN + FP + FN)$	0.85
F1 Skoru	$2 \times (Precision \times Recall) / (Precision + Recall)$	0.91

6. Tartışmalar (Discussions)

Bu çalışmada, 6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş depreminin etkilediği Hatay ilinin Antakya ve Defne ilçeleri üzerindeki seçilen bir örneklem alanında ResNET-34 derin öğrenme algoritması kullanılarak deprem sırasında yıkılan ve yıkılmayan yapılar yüksek doğrulukta tespit edilmiştir. Literatürde de birçok çalışma derin öğrenmenin farklı algoritmalarını kullanarak yüksek doğrulukta yıkılan yapıları tespit edebilmiştir (Vetrivel vd., 2018; Ji vd., 2018; Ma vd., 2019; Rashidian vd., 2019; Toby vd., 2022). Krizhevsky vd. (2012) derin öğrenmenin; görüntü işleme için önceki geleneksel yöntemlerden önemli ölçüde daha iyi performans gösterebilen, hızla gelişen bir teknoloji olduğunu ifade etmişlerdir. Ancak çalışmada uygulanan yöntemin sadece küçük bir örneklem alanında test edilmesi farklı alanlarda yapısal özelliklerin çeşitliliğine bağlı olarak (örneğin; çatı özellikleri, binaların yapı malzemeleri, bina yoğunlukları vb.) benzer başarı oranını ne ölçüde göstereceği üzerinde çalışılması gereken bir soru işaretidir. Gelecekteki çalışmalar, farklı yapısal özelliklere sahip ve çeşitli doğal afet türlerinde algoritmanın performansını ölçmeye yönelik uygulamalarla genelleyici sonuçlar elde etmeyi hedeflemelidir.

Eğitim sürecinde kullanılan veri setlerinin çeşitliliği ve kapsamı, modelin genellenebilirliğini etkileyebilir ve yerel koşulları ve yapı özelliklerini tespit etmek zordur. Açık ki, uydu görüntüleri kullanılarak yapılan derin öğrenme tabanlı hasar tespiti ile yüksek performans elde edilebilse de derinlik bilgisi elde edilemediği için çatıları ağır hasar görmediğinde yıkılan binaların tespit edilmesi zordur (Xiu vd., 2020). Bu sınırlamalar, farklı veri kaynaklarının ve ek saha çalışmalarının elde edilen sonuçları destekleyici ve daha kapsamlı hale getirecek şekilde değerlendirilmesi gerekliliğini ortaya koymaktadır. Bunun yanı sıra Toby vd. (2022)'nin ifade ettiği gibi derin öğrenme algoritmaları kullanarak Uzaktan Algılanan görüntülerden nesne tespiti çalışmalarında, veri setinin niteliğinin modelin

performansını belirlemektedir. Özellikle algoritmanın başarı ölçütleri kullanılan uydu görüntülerinin mekânsal, spektral ve radyometrik çözünürlüklerine bağlı olarak değişebilir.

Ayrıca, derin öğrenme algoritmalarının performansı, uygulayıcı tarafından etiketlenen veri setinin kalitesine ve doğruluğuna da bağlıdır. Bu, etiketleme sürecinde insana bağımlılığın artması anlamına gelmektedir, ki bu da subjektiflik içerebilir ve yanlış sınıflandırmalara yol açabilir. Ayrıca 2023 Kahramanmaraş depremi gibi yıkım etkisinin çok büyük olduğu ve çok fazla hasarın meydana geldiği alanda binaları sadece "yıkıldı" veya "yıkılmadı" şeklinde etiketlemek çok fazla zaman ve emek gerektirir bu da acil müdahalenin gerektiği afet durumlarında bir dezavantaj olarak görülür.

Çalışmada bina ayak izlerinin belirlenmesinde kullanılan OSM verisinin açık kaynaklı ve ücretsiz erişime sahip olması bir avantaj olarak görülse de bu verinin doğruluğu ve güvenilirliği kullanıcı katkılarına dayandığı için her zaman yüksek doğrulukta veya güncel olmayabilir. Bu nedenle yöntemin uygulanması için gerekli olan bina ayak izlerinin afet öncesine ait güncel durumu temsil eden yüksek mekânsal çözünürlüklü görüntülerle güncellenmesi gerekebilir. Özellikle afet durumlarda, verilere erişim, veriler arasında entegrasyon sağlanması ve verilerin güncellenmesi için gereken süre, acil müdahale planlaması gerektiren durumlarda bir dezavantaj olarak görülebilir.

Kendisinden önceki mimarilerden (LeNet, AlexNet, VGGNet, GoogLeNet, ZFNet) daha fazla derinliğe sahip olan ResNet-34'ün (Russakovsky, 2015; Doğan ve Türkoğlu, 2019) yüksek başarısı afet yönetimi süreçlerine entegrasyonunda teknik ve altyapısal engellere de bağlı olabilir. Özellikle teknolojik alt yapının büyük ölçüde etkilendiği afet durumlarında algoritmanın uygulandığı saha koşullarına adaptasyonu için gereken bilgi işlem gücü ve veri iletim altyapısının mevcut olmayışı, bu teknolojilerin yaygın kullanımını sınırlayabilir.

Son olarak depremin yıkım etkisini ve dolayısıyla can ve mal kaybını en aza indirmek amacı ile yapılaşma ve zemin özellikleri arasındaki ilişkiyi göz önünde bulundurmak oldukça önemlidir. Özellikle alüvyon formasyonlar üzerinde kurulan yerleşim alanları büyük risk altındadır. Bunlar; zemin sıvılaşması, oturma, erozyon ve heyelan olarak sıralanabilir ayrıca böyle bir zeminde deprem meydana geldiğinde deprem dalgaları büyüyebilir ve böylece yapıların zarar görmesi kaçınılmaz olur (Bowles, 1996; Ulusay, 1999; Das, 2010). Derin öğrenme algoritmalarının yüksek doğruluk oranı, afet sonrası hasar tespitinin yanı sıra, bu gibi riskli bölgelerde yapıların güvenliğini değerlendirme süreçlerinde de kullanılabilirliğini desteklemektedir. Hatay depremi sonrasında yıkım etkisi en fazla Asi Nehri tarafından biriktirilen alüvyon dolgular ve gevşek zeminler üzerinde meydana gelmiştir. Bu durum, alüvyon formasyonlarının ve gevşek zeminlerin yapı güvenliğini nasıl etkilediğini açıkça göstermiştir. Bu nedenden dolayı bu tür zeminlerde yapılan inşaat projelerinin daha dikkatli bir şekilde planlanması gerekir. Bu bağlamda, derin öğrenme yöntemlerinin sağladığı yüksek doğruluk, afet yönetimi ve şehir planlaması için önemli bir avantaj sunmaktadır.

7. Sonuç (Conclusion)

Bu çalışmada, 6 Şubat 2023 Kahramanmaraş depreminin etkilediği Hatay ilinin Antakya ve Defne ilçeleri üzerinde seçilen bir örneklem alanında ResNET-34 derin öğrenme algoritması ile PLAIDES uydu görüntülerinden yapı hasarı tespiti %85 doğruluk ve %91 F1 skoru oranıyla tespit edilmiştir. Analiz sonuçları afet sonrası hasar tespitinde ResNET-34 derin öğrenme algoritmasının yüksek çözünürlüklü uydu görüntülerinden hasar tespitini etkili bir şekilde belirlediğini göstermiştir. Modelin yüksek doğruluk oranı, derin öğrenme tekniklerinin afet sonrası hasar tespitinde ve yapı güvenliği değerlendirmelerinde etkili bir araç olarak kullanılabileceğini desteklemektedir. Çalışma sonuçları deprem riskine karşı yapıların dayanıklılığını artırmak için zemin özellikleri ile yapılaşmanın entegre bir şekilde ele alınması gerektiğini göstermiştir. Analiz sonuçları, yıkılan binaların büyük ölçüde alüvyon formasyonları üzerinde yoğunlaştığını, özellikle Alüvyon Yelpezesi (Qha) ve Asi Nehri alüvyonlarında önemli hasarların olduğunu ortaya koymuştur. Bu bulgular, gevşek zeminlerin yapı dayanıklılığı üzerindeki olumsuz etkisini açıkça göstermiştir.

Derin öğrenme algoritmalarının yüksek doğruluk kapasitesi hem afet sonrası hasar tespitinde hem de riskli zeminlerde yapı güvenliğini değerlendirmede önemli bir potansiyele sahiptir. Derin öğrenme algoritmalarındaki gelişmeler, gelecekteki afet yönetimi ve şehir planlama uygulamaları için kritik bir avantaj sunacak ve daha güvenli yerleşim alanları oluşturulmasında önemli bir rol oynayacaktır.

Teşekkür (Acknowledgement)

Yazarlar, bu araştırma için Pleiades uydu görüntülerini ücretsiz olarak sağlayan İstanbul Teknik Üniversitesi- Uydu Haberleşmesi ve Uzaktan Algılama Uygulama ve Araştırma Merkezi'ne (İTÜ- CSCRS) teşekkür eder.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Beyen, K., Erdik, M., Mazmanoğlu, C., & Ekmekçiöğlü, Z., 2003. Antakya'nın geçmişten günümüze sismik aktivitesi ve yapılması gerekenlerin bir uluslararası konferansın ışığında değerlendirilmesi. *Engineering Report of Turkey*, 423(1), 51-53.
- Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi. <http://www.koeri.boun.edu.tr/sismo/zeqdb/> (Erişim Tarihi: 03.05.2024)
- Boulton, S.J., Robertson, A.H.F. & Ünlügenç, U.C., 2006. Tectonic and sedimentary evolution of the Cenozoic Hatay Graben, Southern Turkey: A two-phase model for graben formation. In A. H. F. Robertson & D. Mountrakis (Eds.), *Tectonic development of the Eastern Mediterranean Region* Geological Society of London, Special Publications, 206, 613-634.
- Bowles, J. E., 1996. *Foundation analysis and design* (5th ed.). McGraw-Hill International Editions.
- Ci, T., Liu, Z., & Wang, Y., 2019. Assessment of the degree of building damage caused by disaster using convolutional neural networks in combination with ordinal regression. *Remote Sensing*, 11(23), 2858
- Congalton, R. G., & Green, K., 2019. *Assessing the accuracy of remotely sensed data: Principles and practices* (3rd ed.). CRC Press.
- Das, B.M., 2010. *Principles of geotechnical engineering* (7th ed.). Cengage Learning.
- Doğan, F., & Türkoğlu, İ., 2019. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445
- Dubertret, L., & Hudson, R. G. S., 1953. Géologie des roches vertes du nord-ouest de la Syrie et du Hatay (Turquie). *Mémoires Moyen-Orient*, 6, 227.
- Ekin, Ü., 2007. 1822 Halep-Antakya depremi ve bölgeye etkileri. *Türk Kültürü İncelemeleri Dergisi*, 2(17), 29-50.
- Emre, Ö., Duman T. Y., Özalp, S., Elmacı, H., Olgun, Ş., Şaroğlu, F., 2013. Active fault map of Turkey with an explanatory text 1: 1,250,000 scale. *General Directorate of Mineral Research and Exploration, Special Publication Series*, 30, 89.
- Ge, J., Tang, H., & Ji, C., 2023. Self-incremental learning for rapid identification of collapsed buildings triggered by natural disasters. *Remote Sensing*, 15(15), 3909.
- Google Earth: <https://www.google.com/earth> (Erişim Tarihi: 03.05.2024)
- Gursoy, H., Piper, J., Tatar, O., & Mesci, L., 1998. Palaeomagnetic study of the Karaman and Karapınar volcanic complexes, central Turkey: neotectonic rotation in the south-central sector of the Anatolian Block. *Tectonophysics*, 299(1-3), 191-211.
- Gülen, L., Barka, A. A. ve Toksöz, M. N., 1987. Kıtaların çarpışması ve ilgili kompleks deformasyon: Maraş üçlü eklemi ve çevre yapıları. *Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi, Yerbilimleri Dergisi*, 14, 319-336.
- Hacıefendioğlu, K., Başağa, H. B., Kahya, V., Özgün, K., & Altunışık, A. C., 2024. Automatic detection of collapsed buildings after the 6 February 2023 Türkiye earthquakes using post-disaster satellite images with deep learning-based semantic segmentation models. *Buildings*, 14(3), 582.
- 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*. 770-778.
- He, M., Zhu, Q., Du, Z., Hu, H., Ding, Y., & Chen, M., 2016. A 3D shape descriptor based on contour clusters for damaged roof detection using airborne LiDAR point clouds. *Remote Sensing*, 8(3), 189.
- Herece, E., 2008. Doğu Anadolu Fayı (DAF) Atlası. *Maden Tetkik ve Arama Genel Müdürlüğü, Özel Yayın Serisi*, 13. Jeoloji Etütleri Dairesi, Ankara.
- Hinton, G. E., Osindero, S., & Teh, Y. W., 2006. A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Huang, H., Xu, H., Wang, X., & Silamu, W., 2015. Maximum F1-score discriminative training criterion for automatic mispronunciation detection. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 23(4), 787-797.
- Irwansyah, E., Young, H., & Gunawan, A. A., 2023. Multi disaster building damage assessment with deep learning using satellite imagery data *International Journal of Intelligent Systems and Applications in Engineering*, 11(1), 122-131.
- İnik, Ö., & Ülker, E., 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Ji, M., Liu, L., & Buchroithner, M., 2018. Identifying collapsed buildings using post-earthquake satellite imagery and convolutional neural networks: A case study of the 2010 Haiti earthquake. *Remote Sensing*, 10(11), 1689.
- Ji, M., Liu, L., Zhang, R., & F. Buchroithner, M., 2020. Discrimination of earthquake-induced building destruction from space using a pretrained CNN model. *Applied Sciences*, 10(2), 602.
- Jia, J., & Ye, W., 2023. Deep Learning for Earthquake Disaster Assessment: Objects, Data, Models, Stages, Challenges, and Opportunities. *Remote Sensing*, 15(16), 4098.
- Karakuş, K., & Taner, G., 1994. Samandağ formasyonunun (Antakya havzası) yaşı ve molluska faunasına bağlı paleoekolojik özellikleri. *Türkiye Jeoloji Kurumu Bülteni*, 37(2), 87-109
- Korkmaz, H., 2006. Antakya'da zemin özellikleri ve deprem etkisi arasındaki ilişki. *Coğrafi Bilimler Dergisi*, 4(2), 49-66.
- Kranjčić, N., Medak, D., Župan, R., & Rezo, M., 2019. Support vector machine accuracy assessment for extracting green urban areas in towns. *Remote Sensing*, 11(6), 655.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E., 2012. *Imagenet classification with deep convolutional neural networks*. *Adv. Neural Informat. Process. Syst.* 25, 1097-1105.
- Lebègue, L., Greslou, D., Blanchet, G., de Lussy, F., Fourest, S., Martin, V., ... & Amberg, V., 2013. Pleiades satellites image quality commissioning. In *Earth Observing Systems XVIII, SPIE*, 8866, 292-303.

- Li, S., & Tang, H., 2020. Classification of building damage triggered by earthquakes using decision tree. *Mathematical Problems in Engineering*, 1-15.
- Lipton, Z. C., Elkan, C., & Naryanaswamy, B., 2014. Optimal thresholding of classifiers to maximize F1 measure. In *Machine Learning and Knowledge Discovery in Databases: European Conference, ECML PKDD 2014, Nancy, France, September 15-19, 2014. Proceedings, Part II* (225-239). Springer Berlin Heidelberg.
- Ma, H., Liu, Y., Ren, Y., & Yu, J., 2019. Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3. *Remote Sensing*, 12(1), 44.
- Ma, H., Liu, Y., Ren, Y., Wang, D., Yu, L., & Yu, J., 2020. Improved CNN classification method for groups of buildings damaged by earthquake, based on high resolution remote sensing images. *Remote Sensing*, 12(2), 260.
- Menderes, A., Erener, A., & Sarp, G., 2015. Automatic detection of damaged buildings after earthquake hazard by using remote sensing and information Technologies. *Procedia Earth and Planetary Science*, 15, 257-262.
- Moradi, M., & Shah-Hosseini, R., 2020. Earthquake damage assessment based on deep learning method using VHR images. *Environmental Sciences Proceedings*, 5(1), 16.
- Moya, L., Marval Perez, L. R., Mas, E., Adriano, B., Koshimura, S., & Yamazaki, F., 2018. Novel unsupervised classification of collapsed buildings using satellite imagery, hazard scenarios and fragility functions. *Remote Sensing*, 10(2), 296.
- OpenStreetMap: OpenStreetMap. <https://www.openstreetmap.org/>. (Erişim Tarihi: 27.04.2024)
- Over, S., Ozden, S. ve Unlugenç, U. C., 2004a. Late Cenozoic stress distribution along the Misis Range in the Anatolian, Arabian, and African plate intersection region, SE Turkey. *Tectonics*, 23, TC3008
- Over, S., Ozden, S., & Yilmaz, H., 2004b. Late Cenozoic stress evolution along the Karasu Valley, SE Turkey. *Tectonophysics*, 380(1-2), 43-68
- Över, S.; Ünlügenç, U.C.; Özden, S., 2001. Hatay bölgesi etkin gerilme durumu, Hacettepe Üniversitesi., Yerbilimleri Uygulama ve Araştırma Merkezi, *Yerbilimleri Dergisi*, 23, 1-14.
- Pleiades Imagery User Guide: <http://www.astriumgeo.com/en/4572-pleiades-technical-documents> (Ekim 2012)
- Rashidian, V., Baise, L. G., & Koch, M., 2019. Detecting collapsed buildings after a natural hazard on vhr optical satellite imagery using u-net convolutional neural networks. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 9394-9397.
- Rashidian, V., Baise, L. G., Koch, M., & Moaveni, B., 2021. Detecting demolished buildings after a natural hazard using high resolution RGB satellite imagery and modified U-Net convolutional neural networks. *Remote Sensing*, 13(11), 2176.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L., 2015. Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115, 211-252.
- Sarp, G., Erener, A., Duzgun, S., & Sahin, K., 2014. An approach for detection of buildings and changes in buildings using orthophotos and point clouds: A case study of Van Erriş earthquake. *European Journal of Remote Sensing*, 47(1), 627-642.
- Selçuk, H., 1985. Kızıldağ-Keldağ-Hatay dolayının jeolojisi ve jeodinamik evrimi MTA Enstitüsü, *Jeoloji Etütleri Dairesi, Derleme Raporu*, No: 7787, Ankara.
- Sengor, A. M. C., 1979. The North Anatolian transform fault: its age, offset and tectonic significance. *Journal of the Geological Society*, 136(3), 269-282.
- Shafiq, M., & Gu, Z., 2022. Deep residual learning for image recognition: A survey. *Applied Sciences*, 12(18), 8972.
- Şafak, Ü., 1993. Antakya Havzası ostrakod biyostratigrafisi. *Türkiye Jeoloji Bülteni*, 36(2), 115-137.
- Tan, C., Chen, T., Liu, J., Deng, X., Wang, H., & Ma, J., 2024. Building Extraction from Unmanned Aerial Vehicle (UAV) Data in a Landslide-Affected Scattered Mountainous Area Based on Res-Unet. *Sustainability*, 16(22), 9791.
- Toby, T., Gopalakrishnan, U., & Rao, S. N., 2022. A deeper cnn approach for detection of collapsed buildings in drone images. In *Proceedings of the 2022 5th International Conference on Computational Intelligence and Communication Technologies (CCICT)*, 404-410.
- Türk Mühendis ve Mimar Odaları Birliği (TMMOB), 2023. TMMOB Mimarlar Odası 6 ŞUBAT DEPREMLERİ 8. ay değerlendirme raporu. https://www.tmmob.org.tr/sites/default/files/depemin_8_ayina_iliskin_degerlendirmelerimiz.pdf. (Erişim Tarihi: 03.09.2024)
- Türk Tabipleri Birliği (TTB), 2023. VI. Ay Deprem Raporu: Olağandışı Durumlara Dayanısız Birinci Basamak Sağlık Hizmetleri. <https://www.ttb.org.tr/userfiles/files/6ayraporu.pdf> (Erişim Tarihi: 22.06.2024)
- Türkiye İstatistik Kurumu (TÜİK), 2023: <https://data.tuik.gov.tr/> (Erişim Tarihi: 03.05.2024)
- Ulusay, R., 1999. Kentleşme sürecinde yer seçimi ve depreme dayanıklı yapı inşasında jeolojik-jeoteknik etütlerin önemi ve işlevi. *Jeoloji Mühendisleri Odası Yayını*, 51, 23-27.
- Uslu Azarak, L., 2023. Tarihin İzdüşümünde Antakya (Antiokheia) Kentinin Depremselliği. *Vakanüvis-Uluslararası Tarih Araştırmaları Dergisi*, 8, 3210-3228.
- Vetrivel, A., Gerke, M., Kerle, N., Nex, F., & 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*, 140, 45-59.
- Xiu, H., Shinohara, T., Matsuoka, M., Inoguchi, M., Kawabe, K., & Horie, K., 2020. Collapsed building detection using 3D point clouds and deep learning. *Remote Sensing*, 12(24), 4057.
- Yüksel, Ş., 2023. Antakya'nın Deprem Öyküsü. *Modular Journal*, 6(2), 102-106.
- Zhang, Z., Wang, S., Li, Z., Gao, F., & Wang, H., 2023. A Multi-Dimensional Covert Transaction Recognition Scheme for Blockchain. *Mathematics*, 11(4), 1015.