

**GÜMÜŞHANE ÜNİVERSİTESİ \* SOSYAL BİLİMLER ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**YÜKSEK LİSANS PROGRAMI**

**GÖRÜNTÜ SEGMENTASYONU İLE ENTEGRE EDİLMİŞ EVRİŞİMLİ SINIR  
AĞLARI İLE DEPREM SONRASI HASARLI BİNALARIN OTOMATİK  
OLARAK TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Recep KİRİŞ**

**OCAK - 2021  
GÜMÜŞHANE**



**GÜMÜŞHANE ÜNİVERSİTESİ \* SOSYAL BİLİMLER ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**YÜKSEK LİSANS PROGRAMI**

**GÖRÜNTÜ SEGMENTASYONU İLE ENTEGRE EDİLMİŞ EVRİŞİMLİ SINIR  
AĞLARI İLE DEPREM SONRASI HASARLI BİNALARIN OTOMATİK  
OLARAK TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Recep KİRİŞ**

**OCAK - 2021**

**GÜMÜŞHANE**



**GÜMÜŞHANE ÜNİVERSİTESİ \* SOSYAL BİLİMLER ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**YÜKSEK LİSANS PROGRAMI**

**GÖRÜNTÜ SEGMENTASYONU İLE ENTEGRE EDİLMİŞ EVRİŞİMLİ SINIR  
AĞLARI İLE DEPREM SONRASI HASARLI BİNALARIN OTOMATİK  
OLARAK TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Recep KİRİŞ**

**Dr. Öğr. Üyesi Ramazan ÜNLÜ**

**OCAK – 2021**

**GÜMÜŞHANE**

## KABUL VE ONAY

**Dr. Öğr. Üyesi Ramazan ÜNLÜ** danışmanlığında, **Recep KİRİŞ** tarafından hazırlanan “**Görüntü Segmentasyonu ile Entegre Edilmiş Evrişimli Sinir Ağları ile Deprem Sonrası Hasarlı Binaların Otomatik Olarak Tespiti**” isimli bu çalışma, 22/01/2021 tarihinde yapılan lisansüstü tez savunma sınavı sonucunda **Oy Birliği / Oy Çokluğu** ile başarılı bulunarak jürimiz tarafından **Yüksek Lisans / Doktora** Tezi olarak kabul edilmiştir.

.....

**Prof. Dr. Saime ŞAHİNÖZ** ( Başkan )

.....

**Dr. Öğr. Üyesi Ramazan ÜNLÜ** ( Danışman )

.....

**Doç. Dr. Afşin Ahmet KAYA** ( Üye )

Lisansüstü tez savunma sınavında başarılı bulunarak kabul edilen bu tezin ciltlenmiş hali, ..... /..... /..... tarihli ve ..... / ..... sayılı Enstitü Yönetim Kurulu toplantısında görüşülmüş ve Tez Yazım Kılavuzuna uygun bulunarak onaylanmıştır.

.

.....

**Prof. Dr. Ekrem CENGİZ**

**Enstitü Müdürü**

## **BİLDİRİM**

Yüksek Lisans olarak hazırlamış olduğum “Görüntü Segmentasyonu ile Entegre Edilmiş Evrişimli Sinir Ağları ile Deprem Sonrası Hasarlı Binaların Otomatik Olarak Tespiti” isimli bu çalışmanın, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi ve alıntı yaptığım tüm çalışmaların kaynakçada yer aldığını taahhüt eder, tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

22 / 01 / 2021

**Recep KİRİŞ**

## **ÖNSÖZ**

İlk olarak bu çalışmanın gerçekleştirilmesinde en büyük emeği olan, her konuda beni benden daha fazla düşünen, maddi ve manevi boyutta her zaman destek çıkan, bilgilerini her zaman benimle paylaşarak bana birçok yeni bilgiler ve yeni bakış açıları kazandıran, eğitim hayatımın en önemlilerinden olan danışmanın sayın Dr. Öğr. Üyesi Ramazan ÜNLÜ 'ye teşekkürü bir borç biliyor ve şükranlarımı sunuyorum.

Lisans ve Yüksek Lisans süresince gerek alan tecrübelerini gerekse hayat tecrübelerini benimle paylaşarak kendi yolumu çizmemde bana büyük katkıları olan, her birini rol model olarak gördüğüm sayın Prof. Dr. Saime ŞAHİNÖZ 'e, sayın Doç. Dr. Afşin Ahmet KAYA 'ya, sayın Dr. Öğr. Üyesi Sevil CENGİZ 'e ve Dr. Öğr. Üyesi Nurçin KÜÇÜK KENT 'e en içten teşekkürlerimi sunarım.

Hayatım boyunca her daim destek ve dualarını esirgemeyen, her konuda yanımda duran canım aileme ve yakın arkadaşlarıma teşekkürlerimi sunarım.

**Gümüşhane - 2021**

**Recep KIRIŞ**

## ÖZET

**KİRİŞ, Recep. Görüntü Segmentasyonu ile Entegre Edilmiş Evrişimli Sinir Ağları ile Deprem Sonrası Hasarlı Binaların Otomatik Olarak Tespiti, Yüksek Lisans Tezi, 2021, (XII+66)**

Doğal afet türlerinden biri olan depremlerin meydana gelmesinden sonra birçok afetzedenin hayatını kurtarabilmek ve kriz yönetimini daha mükemmel sonuçlandırabilmek için afet bölgesinde bulunan hasarlı binaları mümkün olduğunca en kısa sürede tespit etmek ve tespit edilen hasarlı binalara müdahalelerde bulunmak son derece önemlidir. Günümüzde, deprem sonrasında hasarlı binaların tespiti afet bölgesinde görev alan yetkililer tarafından gözlemlenerek, uydu görüntülerinden veya helikopter gibi hava araçlarından alınan görüntülerden faydalanılarak yapılmaktadır. Yetkililerin gözlemleriyle hasarlı binaların tespiti zaman açısından ciddi kayıplar doğururken, tespitlerin doğruluğu bakımından da güvenilirliği tartışılır düzeydedir.

Bu çalışmada, deprem ve sel gibi beklenmedik afetlerden sonra hasarlı veya tahrip olmuş binaların otomatik olarak tespit edilebilmesi için yapay zeka tabanlı sistemler test edilmiştir. Çalışma sırasında görüntü sınıflandırma literatüründe sıklıkla kullanılan VGG-16, VGG-19 ve NASNet evrişimli sinir ağı modelleri kullanılmıştır. Bu modelleri etkili bir şekilde uygulayabilmek için, önce çalışmada kullanılan tüm görüntüler K-Means kümeleme algoritması ile segmentlere ayrılmıştır. Sonrasında, çalışmanın ilk aşaması için, “hasarlı binalar” ve “normal binalar” olarak etiketlenen resimler sınıflandırılmıştır. VGG-19 modeli test setinde %90 doğruluk oranı elde edilmiştir. Çalışmanın ikinci aşamasında “hasarlı binalar”, “daha az hasarlı binalar” ve “normal binalar” olarak etiketlenen resimler için çok sınıflı bir sınıflandırma algoritması oluşturulmuştur. Bu aşamada VGG-19, VGG-16 ve NASNet test setinde sırasıyla yaklaşık %69, %66 ve %62.5 doğruluk oranı elde edilmiştir.

**Anahtar Kelimeler:** Deprem, Hasarlı Binalar, Yapay Zeka Uygulamaları, Görüntü Sınıflandırma ve Kriz Yönetimi

## ABSTRACT

**KİRİŞ, Recep. Detection Of Damaged Buildings After An Earthquake With Convolutional Neural Networks In Conjunction With Image Segmentation, Master Thesis, 2021, (XII+66)**

After the occurrence of earthquakes, which are types of natural disasters, it is necessary to save the lives of many disaster victims and finalize crisis management more perfectly. So it is extremely important to identify damaged buildings in the disaster zone as soon as possible and to make interventions to the damaged buildings detected. Currently, the detection of damaged buildings after the earthquake is carried out by observing the authorities in the disaster zone, using satellite images or images taken from air vehicles such as helicopters. While detecting damaged buildings with observations by the authorities can bring great losses in terms of time and their reliability in terms of accuracy is debatable.

In this study, artificial intelligence-based systems were tested to automatically detect damaged or destroyed buildings after unexpected disasters such as earthquakes and floods. VGG-16, VGG-19 and NASNet convoluted neural network models, which are often used in the image classification literature, were used during the study. In order to apply these models effectively, firstly all images which used in the study are segmented by the K-Means clustering algorithm. Then, for the first stage of the study, the images labeled as “damaged buildings” and “normal buildings” were classified. The VGG-19 model test set achieved an accuracy rate of %90 . In the second phase of the study, a multi-class classification algorithm was created for images labeled as “damaged buildings,” “less damaged buildings,” and “normal.” At this stage, the VGG-19, VGG-16 and NASNet test sets achieved an accuracy rate of approximately %69, %66 and %62.5 respectively

**Keywords:** Earthquake, Damaged Buildings, Artificial Intelligence Applications, Image Classification and Crisis Management



## İÇİNDEKİLER

DIŞ KAPAK

İÇ KAPAK

KABUL VE ONAY .....	III
BİLDİRİM .....	IV
ÖNSÖZ.....	V
ÖZET.....	VI
ABSTRACT .....	VII
İÇİNDEKİLER .....	VIII
TABLolar LİSTESİ.....	X
ŞEKİLLER LİSTESİ.....	XI
KISALTMALAR LİSTESİ.....	XII

GİRİŞ .....	1
-------------	---

## BİRİNCİ BÖLÜM

1. AFET VE AFET YÖNETİMİ.....	3-12
1.1. Afet Kavramı .....	3
1.2. Afetlerin Sınıflandırılması .....	5
1.3. Afet Yönetimi .....	8

## İKİNCİ BÖLÜM

2. DEPREM .....	13-21
2.1. Deprem Nedir?.....	13
2.2. Deprem Türleri .....	14
2.3. Depremlerin Ölçülmesi.....	16
2.4. Deprem Sonrası Binaların Hasarlarının Sınıflandırılması .....	17

2.5.	Deprem Sonrası Binaların Hasar Tespiti .....	20
------	--	----

### **ÜÇÜNCÜ BÖLÜM**

<b>3. YAPAY ZEKA .....</b>	<b>22-41</b>
3.1. Yapay Zeka Kavramı .....	22
3.2. Yapay Zekanın Kısa Tarihi .....	24
3.3. Yapay Zekanın Alt Dalları .....	26
3.4. Afet Alanında Yapay Zeka Kullanımı .....	38

### **DÖRDÜNCÜ BÖLÜM**

<b>4. GEREÇ VE YÖNTEM .....</b>	<b>42-54</b>
4.1 Problemin Durumu .....	42
4.2. Araştırmanın Amacı .....	42
4.3. Araştırmanın Önemi .....	43
4.4. Araştırmanın Kapsamı .....	43
4.5. Araştırmanın Kısıtlılıkları .....	44
4.6. Araştırma Modeli .....	44
4.7. Veri Toplama Araçları ve Yöntem .....	45
4.8. Bulgular ve Yorumlar .....	47
4.10. Tartışma .....	52

<b>SONUÇ VE DEĞERLENDİRME .....</b>	<b>55</b>
-------------------------------------	-----------

<b>KAYNAKÇA .....</b>	<b>57</b>
-----------------------	-----------

<b>ÖZGEÇMİŞ .....</b>	<b>67</b>
-----------------------	-----------

## TABLÖLER LİSTESİ

Tablo 1. Afet Türleri .....	5
Tablo 2. Afetin Alt Sınıfları .....	6
Tablo 3. Magnitüd (Büyüklik) ve Mercalli (Şiddet) Ölçekleri Karşılaştırması .....	16
Tablo 4. Taş ve betonarme binalar için hasar tipleri .....	18
Tablo 5. Afet Sonrası Binaların Hasar Durumları ve Sınıflandırılması.....	19
Tablo 6. Marmara Depremi Sonrası Hasar Gören Bina Verileri .....	20
Tablo 7. Yapay Zekanın Kısaca Tarihçesi .....	25
Tablo 8. Makine Öğrenmesi Sınıflandırma Teknikleri .....	30
Tablo 9. Derin Öğrenme Mimarileri .....	31
Tablo 10. İnternet Kullanabilen Nesnelerin Afet Alanında Kullanım Örnekleri.....	39
Tablo 11. Afet Alanında Kullanılan Ürün ve Uygulama Örnekleri.....	41
Tablo 12. İkili Sınıflandırma Aşamasında VGG-16, VGG-19 ve NASNet Modellerin Test Setleri İçin Matrisleri .....	49
Tablo 13. VGG-16, VGG-19 ve NASNet'in Duyarlılık, Özgüllük ve G-Ortalama Skorları .....	49
Tablo 14. Çoklu Sınıflandırma Aşamasında VGG-16, VGG-19 ve Nasnet Modellerin Test Setleri İçin Matrisleri .....	51
Tablo 15. VGG-16, VGG-19 ve NASNet'in Çoklu Sınıflandırmada Duyarlılık, Özgüllük ve G-Ortalama Skorları .....	52

## ŞEKİLLER LİSTESİ

Şekil 1. Asya Pasifik Bölgesi Ortalama Yıllık Kayıpların Dağılımı .....	7
Şekil 2. Modern Afet Yönetim Döngüsü .....	10
Şekil 3. Türkiye Deprem Haritası .....	14
Şekil 4. Çökme Depremi .....	14
Şekil 5. Volkanik Depremi.....	15
Şekil 6. Tektonik Depremi .....	15
Şekil 7. Az Hasarlı, Orta Hasarlı ve Ağır Hasarlı Bina Örnekleri .....	18
Şekil 8. Afet Sonrası Uzaktan Algılama Örneği .....	20
Şekil 9. Yapay Zekanın Kullanıldığı Alanlar.....	23
Şekil 10. Yapay Zekanın Alt Dalları.....	27
Şekil 11. Makine Öğrenmesinden Faydalanılan Bazı Alanlar .....	28
Şekil 12. Evrişimli Sinir Ağının Kavramsal Örneği .....	32
Şekil 13. Evrişimli Sinir Ağının Kavramsal Örneği .....	33
Şekil 14. VGG-16 Mimarisi.....	35
Şekil 15. VGG-19 Mimarisi.....	35
Şekil 16. Evrişimli Ağ Mimarisinin Uygulama Örneği .....	36
Şekil 17. Gri Tonlu Görüntü Segmentasyonu .....	37
Şekil 18. Araştırma Modeli .....	44
Şekil 19. Normal ve Hasarlı Binaların Orijinal ve Segmentasyonu Yapılmış Görüntüleri .....	46
Şekil 20. VGG-16, VGG-19 Ve NASNet Modellerinin Epoch (Eğitim Turu) Sayısına Göre Eğitim ve Doğrulama Kayıplarının Değerleri.....	48
Şekil 21. Eğitim ve Doğrulama Setlerinde VGG-16, VGG-19 ve NASNet'in Doğruluk Oranı.....	48
Şekil 22. Çoklu Sınıflandırma İçin Epoch (Eğitim Turu) Sayısına Göre VGG-16, VGG-19 ve NASNet'in Eğitim ve Doğrulama Kayıplarının Değerleri .....	50
Şekil 23. Çoklu Sınıflandırma İçin Eğitim ve Doğrulama Setlerinde VGG-16, VGG-19 ve NASNet'in Doğruluk Oranları.....	51

## KISALTMALAR LİSTESİ

TÜRKÇE		İNGİLİZCE	
AFAD	Afet ve Acil Durum Yönetimi Başkanlığı	CNN	Convolutional Neural Network
ESA	Evrişimli Sinir Ağları	EM-DAT	The International Disaster Database
YSA	Yapay Sinir Ağları		
YZ	Yapay Zeka		

## GİRİŞ

Afetler, bireylerin ve toplumların hayatları, mal ve mülkleri için büyük tehlikeler barındıran olayların sonuçlarıdır. Birçok ülkede telafisi zor zararlara, gelişmekte olan bazı ülkelerde ise çok ciddi maddi kayıplara yol açarak uzun yıllar devam edebilecek duraksamalara sebebiyet vermektedir (Press ve Hamilton, 1999: 1927). Deprem beklenmedik zamanda gerçekleşen, büyük ekonomik kayıplara sebebiyet veren, ölümcül etkileri olan doğal afet türüdür (Hu vd., 1996: 3). Deprem, büyük can ve geçim kaybına neden olan en yıkıcı doğal tehlikelerden biridir. Her yıl ortalama 10.000 kişi deprem nedeniyle hayatını kaybederken, yıllık ekonomik kayıplar da milyonlarca dolara ulaşmaktadır (Elnashai ve Sarno, 2015: xv). Başarılı afet yönetimi, deprem gibi afetlerin verebileceği zararların boyutlarını büyük oranda azaltabilir. Afet yönetiminin temel vazifesi, insan hayatı ve ekonomik zararları en aza indirmek ve ülkeyi bütün afetlere karşın müdafa etmek. Ülkeyi afetlere karşı koruyarak, zarar azaltma, yeniden yapılandırma, koruma ve iyileştirme vb. ilkelerini içinde barındıran planlama sistemidir (Varol ve Kaya 2018:2). Afet yönetimi alanında büyük verilerin kullanıldığı çalışmalarda artış gözükmemektedir. Büyük verilerin kullanımıyla afet yönetiminde yapay zeka, makine öğrenmesi gibi alanlardan da faydalanılmaya başlanılmıştır. Deprem, sel, kasırga gibi birçok afet türlerinde afet yönetiminin farklı farklı aşamalarında yapay zeka ve alt dalları kullanılmaktadır (Yu vd., 2018: 2).

Yapay zeka, insanlar gibi düşünen sistemler, insanlar gibi davranan sistemler, rasyonel düşünen sistemler ve rasyonel davranan sistemlerdir (Kok vd., 2010: 1097). Yapay zeka aktif olarak kullanıldığı birçok alanda ve çalışmalarda kolaylıklar sağlamaktadır (Yağcı vd., 2005: 35). Afet sonrasında binaların hasar tespitlerine yönelik yapılan çalışmalarda da yapay zekanın sağlamış olduğu avantajlardan faydalandığı görülmektedir (Kayı vd., 2015: 227).

Bu çalışmada, depremde hasar görmüş binaları tespit etmek için yapay zeka alanı içerisinde olan derin öğrenmesi algoritmalarından evrişimli sinir ağlarının kullanıldığı önceden eğitilmiş modeller oluşturulmuştur. Çalışma sırasında modellerin daha kolay analiz yapılabilmesi için görüntü segmentasyonu tekniğinden faydalanılmıştır. Ayrıca çalışmada veri olarak kullanılan görüntüler “drone” gibi insansız hava araçlarından faydalanılarak alınması planlanmıştır. Çalışmada uygulanan modeller yüksek doğruluk

oranıyla sonuçlanmıştır. Çalışma; günümüzde uygulanan bina hasar tespit uygulamaları dışında insansız hava araçları kullanıldığı için afet yönetimine zaman ve mali açısından büyük avantaj sağlayacaktır. Ayrıca afet yönetimi alanında yapay zekanın kullanımının önemine dikkat çekerek bu alandaki çalışmaların artması yönünde teşvik edici niteliktedir.

## BİRİNCİ BÖLÜM

### 1. AFET VE AFET YÖNETİMİ

#### 1.1. Afet Kavramı

5902 sayılı Afet ve Acil Durum Yönetimi Başkanlığının Teşkilat ve Görevleri Hakkında Kanun'a göre afetin tanımı; toplumların bütünü ve maruz kalan belirli gruplar için, sosyal, ekonomik ve fiziksel kayıpları sebep olan, insanların gündelik faaliyetleri ve yaşamını sona erdiren veya sekteye uğratan, beşeri, teknolojik ve doğal kaynaklı olayların tümüdür. (Afet ve Acil Durum Yönetimi Başkanlığının Teşkilat ve Görevleri Hakkında Kanun, 2009: 10449).

Meydana geldiğinde can ve mal kaybına sebebiyet veren, toplumların günlük yaşantılarını kesintiye uğratan, maruz kalanların kendi imkanları ile başa çıkamadığı ve meydana geldiği bölgede ki yerel yönetimlerin yetersiz kaldığı, tüm devlet kurum ve kuruluşları ile birlikte sivil toplum kuruluşlarının desteklerini gerektiren, fiziksel, sosyal ve ekonomik kayıplara sebebiyet veren doğal ya da beşeri kaynaklı olayların sonucudur (Ergünay, 1996).

Afet, toplumu oluşturan unsurların zarar görmesine veya yok olmasına sebep olan, meydana geldiğinde gereken ihtiyaçlara karşı yerel imkanların yetersiz kaldığı olayların sonuçlarıdır (Tzeng vd., 2016: 2).

Afetler yer, zaman ve büyüklük fark etmeksizin meydana gelmeye başladığı günden itibaren toplumda can ve mal kaybına neden olan olayların sonuçlarıdır. Afetler çoğu ülkede ciddi oranda büyük kayıplara sebebiyet vermişlerdir. Etkileri ülkelerin gelişmişlik ve afetlere hazırlıklı olmalarına göre değişiklik göstermekte ve gelişmemiş ülkeleri daha çok etkilemektedir (Press ve Hamilton, 1999: 1927).



Afetlerin şiddetini etkileyen birçok parametreler vardır. Afeti etkileyen ana parametreler şunlardır:

1. Afetin fiziksel büyüklüğü,
2. Afetin gerçekleştiği konumunun, yerleşim alanlarına olan uzaklığı,
3. Afetin meydana geldiği ülkelerin ekonomik gelişmişlik düzeyi,
4. Doğal çevre tahribatı veya yanlış kullanımı,
5. Hızlı ve denetimsiz sanayileşme ve yerleşim alanı oluşturma,
6. Bilgisizlik ve eğitim eksikliği,
7. Afete karşı alınan önlemlerin yeterlilik düzeyi (Arca, 2012: 55).

Yukarıdaki parametrelere göre afetlerin şiddetini, büyük çoğunlukla insan faaliyetlerinin etkilediği görülmektedir.

Afetlerin genel özellikleri incelendiğinde;

- Afetlerin neden olduğu can ve mal kayıpları toplum üzerinde olumsuz psikolojik etkilere neden olur.
- Altyapı sistemlerini (enerji, su, elektrik vb.) bozmasından dolayı ekonomik kayıplar doğurur.
- Ekonomik kalkınmayı zorlaştırır.
- Afetlerin toplum üzerinde ki olumsuz etkileri uzun süre devam edebilir.
- Afetzedeler, afet meydana geldiği andan itibaren kendi imkanları ile baş edemeyecekleri için dış desteğe ihtiyaç duyacaklardır.
- Afete maruz kalan kitlenin büyüklüğüyle afetin etkisi doğru orantılıdır (Yılmaz, 2003).
- Afet, afetzedeleri kendi imkanlarıyla baş etmelerinde yetersiz bırakır (Kadioğlu, 2008: 5).
- Afet bir vaka değildir, vakanın meydana getirdiği sonuçlarıdır (İlhan, 2013: 108).
- Doğada su ve hava kirliliği gibi problemlere neden olması olumsuz etkilerindendir (Tercan, 2008).

## 1.2. Afetlerin Sınıflandırılması

Afet türleri hakkında literatürde çeşitli sınıflandırmalar mevcuttur. Afet türlerinin sınıflandırılmasında bazı kaynaklarda doğal ve insan kaynaklı afetler olarak ikiye ayrılırken, bazı kaynaklarda doğal ve teknoloji kaynaklı afetler olarak ikiye ayrılır. Bazı kaynaklarda ise doğal, insan kaynaklı ve teknolojik kaynaklı afetler olarak üçe ayrıldığı görülmektedir.

AFAD, afet türlerini doğal ve insan kaynaklı afetler olarak iki ana gruba ayırmıştır. Doğal afetleri kendi arasında meydana geliş süreçlerine göre yavaş gelişen ve ani gelişen doğal afetler olarak ikiye ayırmıştır. İnsan kaynaklı afetlerde kaza çeşitlerine ve göçmenler olarak yer vermiştir (<https://www.afad.gov.tr/afet-turleri>, 2020).

**Tablo 1. Afet Türleri**

DOĞAL AFETLER		İNSAN KAYNAKLI AFETLER
Yavaş Gelişen Doğal Afetler	Ani Gelişen Doğal Afetler	
Kuraklık Şiddetli Soğuklar	Deprem Yangınlar	- Nükleer, Biyolojik, Kimyasal Kazalar
Kıtlık vb.	Seller, Su Taşkınları	- Taşımacılık Kazaları
	Çığ	- Endüstriyel Kazalar
	Fırtınalar, Hortumlar Toprak Kaymaları	- Aşırı Kalabalıktan Meydana Gelen Kazalar
	Kaya Düşmeleri Volkanlar vb.	- Göçmenler ve Yerlerinden Edilenler vb.

Kaynak: <https://www.afad.gov.tr/afet-turleri> (2020)

Güncel afet kayıtlarını tutan Uluslararası Afet Veri Tabanı (EM-DAT) afetlerin genel sınıflandırılmasında afetleri doğal ve teknolojik olarak iki ana sınıfa ayırılmış olup doğal kaynaklı afetleri jeofizik, meteorolojik, hidrolojik, klimatolojik, biyolojik ve dünya dışı olarak alt sınıflara ayırırken, teknolojik afetleri ise taşıma kazaları, endüstriyel kazalar ve çeşitli kazalar olarak alt sınıflara ayırmıştır (<https://www.emdat.be/classification>; 2020).

**Tablo 2. Afetin Alt Sınıfları**

Genel Sınıflandırma		
Afet Grubu	Afet Alt Grubu	Afet Ana Türü
Doğal	Jeofizik	Deprem
		Kütle Hareketi
		Volkanik Faaliyet
	Meteorolojik	Aşırı Sıcaklık
		Sis
		Fırtına
	Hidrolojik	Sel
		Heyelan
		Dalga Hareketleri
	Klimatolojik	Kuraklık
		Buzul Patlaması
		Orman Yangını
	Biyolojik	Epidemi
		Böcek İstilasası
		Hayvan Kazası
	Dünya Dışı	Etki
		Uzay Havası
Teknolojik	Endüstriyel Kaza	Kimyasal Dökülme
		Çöküş
		Patlama
		Ateş
		Gaz Sızıntısı
		Zehirlenme
		Radyasyon
		Yağ Sızması
		Diğer
	Taşıma Kazası	Hava
		Yol
		Demiryolu
		Su
	Çeşitli Kaza	Çöküş
		Patlama
		Ateş
		Diğer


Kaynak: <https://www.emdat.be/classification>; (2020)

### 1.2.1. Doğa Kaynaklı (Doğal) Afetler

Doğa olayları nedeniyle meydana gelen ve toplumun günlük yaşantısını kesintiye uğratan afetlere “doğal afetler” denmektedir. Avrupa Atlantik Afet Müdahale Merkezi Yönergesi deprem, toprak kayması, sel, çevre kirlenmesi, volkan patlaması, kasırga, kuraklık, çölleşme ve dev dalgalar gibi afetleri doğal afetler olarak kabul etmektedir (Büyükbaş ve Ormanoğlu y.y.: 16).

Doğal afetler, durağan olmayan zamansal döngüler doğrultusunda çeşitli eğilimler sergileyen afetlerdir. Doğal afetler, uzun dönemli hareketleri ve zamansal verileri gözlemlenerek daha belirgin hale getirilebilir (Hoyois vd., 2007: 18).

**Şekil 1. Asya Pasifik Bölgesi Ortalama Yıllık Kayıpların Dağılımı**



Kaynak: AFAD Afet Yönetimi Kapsamında 2019 Yılına Bakış ve Doğa Kaynaklı Olay İstatistikleri, 2020

#### 1.2.1.1. Yavaş Gelişen Doğal Afetler

Yavaş gelişen doğal afetler bir anda gerçekleşmemekte ve ortaya çıkma süreleri daha uzun aralığı kapsamaktadır. Bu sayede yavaş gelişen afetlere karşı önleme ve koruma tedbirleri alma olanağı daha kolaydır. Kuraklık, şiddetli soğuklar ve kıtlık gibi afetler yavaş gelişen doğal afetler grubunda yer almaktadır (Tercan, 2019: 26).

#### 1.2.1.2. Ani Gelişen Doğal Afetler

Ani gelişen doğal afetler beklenmedik bir anda meydana gelen doğal afet türleridir. Beklenilmeyen anda meydana gelmesinden dolayı öncesinde alınmış önleyici ve koruyucu tedbirler yetersiz ise büyük can ve mal kayıplarına neden olarak normal

hayatı fazlaca kesintiye uğratabilir. Ani gelişen afetlere depremler, seller, su taşkınları, fırtınalar, hortumlar, yangınlar, volkanlar vb. gibi afet türlerini örnek verilebilir (Tercan, 2019: 26).

### **1.2.2. İnsan Kaynaklı Afetler**

İnsan kaynaklı afetler, literatürde karşımıza bazen “doğal olmayan afetler” olarak çıkmaktadır. Bu tür afetlerin meydana gelmesindeki etmenler ile doğa olayları arasında hiçbir bağlantı olmayıp meydana gelmesinde tamamen insani faktörlerin veya insan yapımı aletlerin sebep olduğu afetlerdir. Bu afetler de doğal afetler gibi çok büyük zararlara neden olabilir. İnsan kaynaklı afetlere kimyasal kazalar, endüstriyel kazalar vb. gibi afetler örnek verilebilir (Altun, 2018: 5).

### **1.2.3. Teknoloji Kaynaklı (Teknolojik) Afetler**

“Doğal yollarla gerçekleşmeyen” kişilerin bilinçsizce davranarak önemsemedikleri etkinlikler yüzünden meydana gelen ve teknolojik alanında gelişme gösteren durumları da içeren afetlerdir. Enerji ihtiyacını karşılamak amacıyla kurulan nükleer santrallerde meydana gelen kazalar, endüstriyel sektörde gerçekleşen kazalar, biyolojik ve kimyasal maddelerin kazaları, hava, kara ve denizyolu ulaşım araçlarında meydana gelen kazalar vb. vakalar teknoloji kaynaklı afetler sınıfına girmektedir. Bu afetler kendiliğinden olabileceği gibi bir kişi tarafından ya da doğa kaynaklı bir afetin neden olmasıyla da meydana gelebilir (Kadıoğlu, 2008: 6) .

## **1.3. Afet Yönetimi**

Afet yönetimi, afet sonucu meydana gelebilecek olayların önlenmesi, zararların azaltılması için yapılan hazırlık çalışmalarında ve afet sonrası müdahale ve iyileştirme çalışmalarında hiç kimseyi mağdur etmeyecek şekilde tüm toplumu kapsayan planlar, mevzuatlar ve kurumsal yapılar oluşturulması, düzenlenmesi ve etkili şekilde uygulanabilmesidir (Kadıoğlu, 2008: 7)

Erkal ve Değerliyurt’a göre afet yönetimi, afetlerin önlenip zararların azaltılması için afete neden olabilecek tüm tehlike ve risklerin iyi bilinip gözlenmesi, olaylar gerçekleşmeden önce alınması gereken tüm önlemlerin alınarak yol açabilecekleri olumsuzlukların azaltılmasını gerektiren bir mücadeledir. Bu mücadele en sade bireyden

en yetkili makamlarda ki bireylere kadar tüm toplumu kapsar, herkese görev ve sorumluluk yükler (Erkal ve Değerliyurt, 2009: 151)

Afet yönetimi, afetin sebep olacağı kayıpları önlemeyi ve azaltmayı, afetzedeleri hızlıca ulaşıp yardım etmeyi, afetin etkilerini hızlı ve etkili şekilde iyileştirmeyi amaçlamaktadır (Warfield, 2008'den aktaran Shafiq ve Ahsan, 2013: 62).

Afet yönetimi sistemini gelişimini incelediğimizde klasik afet yönetimi, bütünleşik afet yönetimi ve modern afet yönetim sistemleriyle karşılaşmaktadır. Klasik afet yönetim sistemi daha çok afet sonrası afetin sebep olduğu yaraları sarmak üzerine odaklanmaktadır. Bütünleşik afet yönetimi, afet risk yönetimi ve afet kriz yönetimi olmak üzere iki evreden oluşmaktadır (Kadıoğlu, 2008: 9-10). Modern afet yönetimi ise afet öncesindeki aşama için zarar azaltma ve hazırlık evreleri, afet gerçekleştikten sonraki aşamalar için müdahale ve iyileştirme evreleri olmak üzere toplamda 4 evreden oluşmaktadır (Uysal vd. 2018: 219).

Afet yönetimi;

- Afet risklerinin tespiti ve ortadan kaldırılması,
- Afetlerin verebileceği zararların etkisini en aza indirmek,
- Meydana gelebilecek olayların senaryolaştırabilmesi halinde ihtiyaçların belirlenmesi,
- Planlamalar ve hazırlıklar yapma,
- Afet bilinci eğitimleri verilmesi ve tatbikatların uygulanması,
- Afetin öncesinde tahmin, erken uyarı çalışmaları,
- Afet sonrası ihtiyaçların tespiti ve erken yanıt verme,
- Afet anında hızlı müdahale çalışmaları gerçekleştirme,
- Afet sonrasında iyileştirme gibi bütünleşik, kapsamlı, disiplinler şekilde önleme, planlama ve müdahale iyileştirme çalışmalarının tümüdür (Eygü ve Karabacak, 2017: 633).


Afet yönetiminin temel vazifesi, insan hayatı ve ekonomik zararları en aza indirmek ve ülkeyi bütün afetlere karşı müdafaa etmektir. Ülkeyi afetlere karşı koruyarak, zarar azaltma, yeniden yapılandırma, koruma ve iyileştirme vb. ilkelerini

içinde barındıran planlama sistemidir. Tehlike ve risk odaklı bir acil durum, afet yönetim planı ve uygulamaları afete maruz kalma riski bulunan bireylere nasıl uyarmalı, yardımcı olmalı ve ne yapacakları konusunda yol göstermelidir (Varol ve Kaya 2018:2).

### 1.3.1. Afet Yönetimi Aşamaları

Afetlerin sonucunda oluşan zararlar, tesirli bir afet yönetim planlamasına neden gerekli olduğunu açık bir şekilde gözler önüne sermektedir. Bu yüzden, etkili bir afet yönetim planının; hazırlanması, sürekli olarak tatbik edilmesi, değişen şartlara göre revize edilmesi ve eksiksiz şekilde uygulanabilir esneklikte olması önem arz etmektedir (Aydiner, 2014: 21).

Şekil 2. Modern Afet Yönetim Döngüsü



Kaynak: Reasürör Dergisi, 2017: 7

#### 1.3.1.1. Afet Risk Yönetimi

Afet risk yönetimi; afet öncesi belirlenen risklerin ve tehlikelerin afet öncesinde ortadan kaldırılması veya en aza indirilmesine yönelik planlamaların ve çalışmaların gerçekleştirilmesidir. Bu aşamada afetten etkilenebilecek tehlike ve riskler belirlenerek olası risk senaryoları hazırlanmakta, koruma çalışmaları gerçekleştirilmekte, geçmiş dönemlerdeki afetler de göz önünde bulundurularak bölgesel haritalamalar ve grafikler

oluşturulmakta, afette ve sonrasında kullanılabilecek kaynaklar belirlenmektedir (Özkul ve Karaman, 2007: 256).

**a) Zarar azaltma:**

Bireylerin refah düzeyi, sağlık, can ve mal güvenliği gibi durumlarına zarar verme potansiyeline sahip risklerin ortaya çıkması halinde oluşacak zararı en aza indirmek için bir zarar azaltma planı hazırlanıp uygulanması bu aşamayı içermektedir (Petak, 1985: 3).

Afetin etkilerini en aza indirmek için yapılan çalışmaları içerir. Bina imar düzeltmeleri, güvenlik açığı analizleri ve açığı kapatma işlemleri, topluma afet bilinci eğitimi verilmesi gibi çalışmalar zarar azaltma çalışmalarına örnek verilebilir. Afetlerin veya felaketlerin neden olacağı olumsuz etkileri sınırlandırmak için alınan önlemleri ve önlemler doğrultusunda yapılan çalışmaları içerir (Messer, 2003: 5). Diğer bir deyişle zarar azaltma, uzun mühletle kişinin can ve mal güvenliği açısından tehdit oluşturan durumlara karşı alınması gerekli olan etkili tedbirlerin bütünüdür (McCloughlin, 1985: 165).

**b) Hazırlık:**

İnsanoğlu afetleri tamamen önleyemediği için afetin etkilerini azaltma yönünde afete hazırlık çalışmaları gerçekleştirmektedir. Hazırlık aşamasında zarar azaltmaya entegre şekilde afetin etkilerini tetikleyebilecek unsurları ortadan kaldırmak, afet yönetiminde görev alacak kurum ve personelin yetki ve sorumluluklarını belirlemek, destek kaynaklarını organize etmek temel amaçtır (Uğur ve Işık, 2020: 100).

Afet öncesinde risk ve tehlikeleri ortadan kaldırmak için yapılan tüm çalışmaları kapsar. Her alanda çalışmalar yaparak sosyal ve fiziksel yapıyı afetlere karşı dirençli hale getirme amaçlayan süreçtir (Kadıoğlu, 2008: 18).

**1.3.1.2. Afet Kriz Yönetimi**

Afet yönetiminde afet gerçekleşikten sonraki dönem afet kriz yönetimi kapsamına girmektedir. Afetlerin neden olduğu kriz süreci kargaşalara yol açan, uzun ve zorlu müdahaleler gerektirebilen süreçtir (Aktel, 2007: 151).



**a) Mdahale ařaması:**

Afet gerekleřtikten sonra mmkn olabildiđince ok fazla sayıda kiřinin hayatını kurtarmak ve sađlık durumlarını iyileřtirmek, afetzedelerin hayati ihtiyalarının en kısa zamanda gidermek, yařamın bir an nce eskiye dnmesini sađlamak ve afetlerin neden olabileceđi diđer tehlikeli durumlardan kiřinin hayatını ve mal varlıđını korumak bu ařamanın amacı olarak sylenebilir (Erkal ve Deđerliyurt 2009: 153). Afet meydana gelmesiyle bařlayarak maruz kalınan afetin byklđ ve řiddetine gre en fazla 3 gn ile 1- 2 aylık zaman erevesi ierisinde gerekleřtirilen uygulamalardır (Kadiođlu, 2008: 23).

**b) İyileřtirme ařaması:**

Afetin etkilerini ortadan kaldırarak normal hayata dnmek iin gerekleřtirilen alıřmaları kapsayan ařamadır. Genellikle mdahale ařaması ile eř zamanlı i ie devam eder (Bařbakanlık Kriz Ynetim Merkezi, 2000'den aktaran İskender ve Erdođan, y.y.: 323).

Afetin sebep olduđu kargařa getikten sonra normal yařamın yeniden dzenlenmesi iin yođun alıřmaların yapıldıđı alıřmalardır. İyileřtirme ařaması elektrik, su, kanalizasyon, haberleřme vb. altyapılarının yenilenmesi gibi afetzedelerin normal hayatlarına devam etmelerini sađlayacak sistemi yeniden dzenlemek iin yapılan faaliyetleri ierir (oban, 2019: 241).

## İKİNCİ BÖLÜM

### 2. DEPREM


Bu bölümde depremlerin türleri, şiddet ve büyüklük ölçekleri, depremlerin vermiş olduğu hasarlı binaların sınıflandırılması ve hasar tespit yöntemleri incelenecektir.

#### 2.1. Deprem Nedir?

Deprem beklenmedik zamanda gerçekleşen, büyük ekonomik kayıplara sebebiyet veren, ölümcül etkileri olan doğal afet türlerinden biridir (Hu vd., 1996: 3). Depremler, büyük can ve geçim kaybına neden olan en yıkıcı doğal tehlikelerden biridir. Her yıl ortalama 10.000 kişi deprem nedeniyle hayatını kaybederken , yıllık ekonomik kayıplar da milyonlarca dolara ulaşmaktadır (Elnashai ve Sarno, 2015: xv).

Deprem, yer kabuğu hareketlerine denmektedir. Ani bir şekilde ortaya çıkmalarından dolayı çoğu zaman can ve mal kayıplarına neden olan, toplum üzerinde korku saçan olaylardır (Sür, 1993: 53). Depremler, yeri ve zamanı belli olmayan, sonuçlarının can ve mal kayıplarına sebep olabilecek doğa olaylarıdır (Özkul ve Karaman, 2007: 252). Yer kabuğunun katmanlarında görülen hareketler sırasında oluşan titreşimler depremlerin meydana gelmesine neden olmaktadır. Depremler, günümüz teknolojisiyle önceden tahmin edilemez ve meydana gelmesi engellenemez doğa olaylarıdır (İşçi, tarih yok: 959).

**Şekil 3. Türkiye Deprem Haritası**




Kaynak: <https://deprem.afad.gov.tr/deprem-tehlike-haritasi> (2020)

## 2.2. Deprem Türleri

Depremler, “çökme”, “volkanik” ve “tektonik” olarak sınıflandırılırlar (Sür, 1993: 53).

- a. **Çöküntü depremler:** Yer altında bulunan maden, mağara gibi boşlukların aniden çökmelerinden dolayı oluşan depremlerdir. Etkileri ve hissedilme düzeyi fazla olmayan deprem türleridir (Işın, 2004: 7).


**Şekil 4. Çökme Depremi**



Kaynak: <https://www.nkfu.com/deprem-nedir-ve-depremlerden-korunma> (2020)

- b. Volkanik depremler:** Yanardağların patlama öncesi veya patlama sırasında oluşan depremlerdir (İşin, 2004: 7).


**Şekil 5. Volkanik Depremi**



Kaynak: [https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem- cesitleri-nelerdir/](https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem-cesitleri-nelerdir/) (2020)

- c. Tektonik depremler:** Yer kabuğunda oluşan tektonik hareketler sonucu ortaya çıkan deprem türleridir. Oluşan depremlerin %90'ı tektonik depremlerdir (İşçi, 2008: 961).

**Şekil 6. Tektonik Depremi**



Kaynak: [https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem- cesitleri-nelerdir/](https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem-cesitleri-nelerdir/) (2020)

### 2.3. Depremlerin Ölçülmesi

Deprem boyutu şiddeti ve büyüklüğü olmak üzere farklı iki yolla ölçülür. Deprem şiddeti; hissedilen konumda bulunan yapıların ve insanların üzerinde oluşan etkinin ölçüsüdür. Deprem büyüklüğü; deprem sırasında ortaya çıkan enerjinin ölçüsüdür (www.afad.gov.tr, 2020). Deprem büyüklüğü, salınan elastik enerjinin göreceli boyutunu veya miktarını karakterize eden bir sayıdır (Bormann, 2020: 1).

Deprem şiddetinin ölçüsü, deprem sırasında yıkılan cisimlere, mobilyaların hareketliliğine, binaların aldığı hasarlara ve insanların etkilenme düzeylerine bakılarak belirlenmektedir. 1902’de İtalyan Jeolog Giuseppe Mercalli deprem şiddet ölçeğini 12 dereceli şiddet ölçeğine göre ayırmıştır. Deprem büyüklüğünü ölçen magnitüdün ölçümü formüllere dayanırken, şiddetin ölçümü tamamen gözlemlere dayanmaktadır (Kasap ve Gürten, 2003: 158). Deprem büyüklüğü ile ilgili ilk makale 1935’de Charles F. Richter tarafından yazılmıştır. Richter, makalesinde deprem anında ortaya çıkan enerjinin ölçülendirilmesi için “magnitüd” ölçeğini tanımlamıştır. Bu sebeple depremin açığa çıkardığı enerjinin ölçülmesinde makalede yayımlanan magnitüd deprem ölçüm ölçeği baz alınır (Bormann, 2020: 1).

**Tablo 3. Magnitüd (Büyüklik) ve Mercalli (Şiddet) Ölçekleri Karşılaştırması**

Magnitüd (Büyüklik)	Mercalli (Şiddet)	Açıklama
1 – 3	I	Neredeyse hiç hissedilmez.
3 – 3.9	II	Özellikle binaların üst katlarında bulunan insanlar tarafından hissedilebilir.
	III	Hissedilen sarsıntı, büyükçe kamyonun geçişi sırasında hissedilen sarsıntı gibidir. Binalarda bulunan insanlar açıkça hisseder, fakat deprem olduğunu anlamayabilirler.
4 – 4.9	IV	Büyük bir tır binaya çarpmış gibi sarsıntı meydana gelir. Binalarda bulunan herkes tarafından hissedilebilir. Dışarıda bulunanların çok azı sarsıntıyı hissedebilir. Pencere, tabaklar, kapılar titremeye başlar. Duvarlardan çatırcasına sesler gelir. Duran araçlar gözle görünür şekilde sallanmaya başlar.
	V	Herkes tarafından hissedilebilir ve gece vakti uyuyan insanlar uykusundan uyanır. Pencere ve tabaklar kırılmaya, nesneler devrilmeye başlar.
5 – 5.9	VI	Herkes tarafından korkutucu şekilde hissedilir. Ağır mobilyalar hareketlenmeye, sıvalar da dökülmeye başlar. Hafif hasarlara sebebiyet verir.

	VII	İyi inşa edilmiş binalarda hafif ve orta ölçüde hasarlar verirken, kötü inşa edilmiş binalarda ise önemli hasarlara yol açar. Bazı bacalar yıkılır.
6 – 6.9	VIII	Normal binalar orta hasarlar alırken, kötü inşa edilen binalar büyük ölçüde hasar alırlar. Bacalar devrilir, duvar ve kolonlar yıkılır, ağır mobilyalar devrilir.
	IX	Binalar temellerinden kaymaya başlar. Normal inşa edilen binalar büyük ölçüde hasar alırken bazılarında yıkımlar gerçekleşir.
7 veya 7 üzeri	X	İyi inşa edilmiş binalar yıkılmaya başlar. Demiryolları eğilip, bükülmeye başlar.
	XI	Demiryolları büyük oranda hasar alır. Çoğu bina ve köprüler yıkılır.
	XII	Bütün binalar yıkılır, bölgenin yeryüzü şeklinde değişiklikler görülür.











Kaynak: İşçi, 2008: 966

Yukarıdaki tabloda depremin magnitüd ölçeği ve mercalli şiddet skalası karşılaştırılması verilmiştir.

#### 2.4. Deprem Sonrası Binaların Hasarlarının Sınıflandırılması

Deprem nedeniyle binalarda çeşitli düzeylerde hasarlar oluşmaktadır. Oluşan hasarlar az hasarlı, orta hasarlı, ağır hasarlı veya yıkılmış olarak sınıflandırılmaktadır. Az hasarlı binalarda; taşıyıcı elemanlarda sıva çatlaklıkları, bölme duvarlarda hafif çatlaklar, kısmi sıva dökülmeleri, çatı kalkan duvarlarda yıkılmalar olabilmektedir. Orta hasar binalarda; taşıyıcı elemanlarda sıva çatlaklarından daha derin çatlaklar, bölme duvarlarda kısmi ya da tamamen çatlaklar, sıvalar ve fayanslarda dökülmeler meydana gelebilmektedir. Ağır hasarlı binalarda; düşey taşıyıcı elemanlarda kesme çatlakları, binanın stabilizesinde bozulmalar, düşey taşıyıcı elemanlarda bükülmeler ve taşıma kapasitesinde bozulmalar görülmektedir (Çatal, 2019: 277).

**Tablo 4. Taş ve betonarme binalar için hasar tipleri**

Taş Bina	Betonarme Bina	Hasar Seviyesi
		Seviye 1: Az Hasarlı Bina
		Seviye 2: Orta Hasarlı Bina
		Seviye 3: Ağır Hasarlı Bina
		Seviye 4: Çok Ağır Hasarlı Bina
		Seviye 5: Yıkım

Kaynak: Schweier ve Markus, 2006: 181

**Şekil 7. Az Hasarlı, Orta Hasarlı ve Ağır Hasarlı Bina Örnekleri**



Kaynak : Çatal, 2019: 277

**Tablo 5. Afet Sonrası Binaların Hasar Durumları ve Sınıflandırılması**

Hasar tipi	Hasar Tanımı	Örnek
Ağır hasarlı veya yıkım	Bina kullanılamaz durumdadır.	Yapı tamamen çökmüştür.
Orta hasarlı	Güçlendirme ile kullanılabilir.	Duvarlarda patlamalar gözlemlenebilir.
Az hasarlı	Az bir onarımla kullanılabilir.	Duvarlarda gözlenen sıva çatlakları vardır.
Hasarsız	Hasarsız olduğu için kullanılabilir	Hasar yoktur.

Kaynak: Corbane, C. vd., 2011'den aktaran Dong ve Shan, 2013: 86

30 Ekim 2020 yılında İzmir'de gerçekleşen depremin AFAD tarafından yapılan hasar tespit çalışmaları sonrasında 30.11.2020 tarihi itibarıyla İzmir genelinde 511 orta hasarlı bina, 449 ağır hasarlı bina ve 24 yıkık bina olduğu, Manisa'da ise 1 ağır hasarlı bina ile 1 yıkık bina olduğu tespit edilmiştir (AFAD, 2020: 17).

24 Ocak 2020 Elazığ-Sivrice depremi değerlendirme raporuna göre; Elazığ ilinde 263 yıkık, 558 yıkılacak, 7.698 ağır hasarlı, 1.540 orta hasarlı bina olmak üzere 10.059 hasarlı bina tespit edilmiştir. Malatya ilinde 333 yıkık, 281 yıkılacak, 3.181 ağır hasarlı, 512 orta hasarlı bina olmak üzere 4.307 hasarlı bina tespit edilmiştir (Çağlar vd., 2020: 7).

23 Ekim 2011 yılında Van'da gerçekleşen depreminin AFAD tarafından yapılan hasar tespit çalışmaları sonrasında 28.10.2020 tarihi itibarıyla Van genelinde 13.765 bina yaşanamayacak boyutta hasar alırken, 12.542 bina yaşanabilir boyutta hasar almıştır (Van\_Eq\_ED-15112011-2.pdf (boun.edu.tr), 2020).



**Tablo 6. Marmara Depremi Sonrası Hasar Gören Bina Verileri**

	Ölü Sayısı	Yaralı	Ağır-Yıkık Konut-İşyeri	Orta Hasarlı Konut-İşyeri	Az Hasarlı Konut-İşyeri
<b>Kocaeli</b>	4,083	4,149	3,278	3,213	4,458
<b>Gölcük</b>	4,428	5,064			
<b>Sakarya</b>	2,627	5,084	9,907	2,698	5,051
<b>Yalova</b>	2,496	4,472	9,123	7,997	11,302
<b>Bolu</b>	264	1,163	2,384	2,999	1,874
<b>Bursa</b>	263	348	32	109	431
<b>Eskişehir</b>	86	95	70	32	204
<b>İstanbul</b>	976	3,547	2,840	10,380	8,059
<b>Tekirdağ</b>	-	35	-	-	-
<b>Zonguldak</b>	3	26	-	-	-
<b>Genel Toplam</b>	15,226	23,983	27,634	27,428	31,379

Kaynak: Devlet Planlama Teşkilatı, 1999

Tablo 6'ya göre 1999 yılında gerçekleşen Marmara depreminde toplam 86.441 binanın hasar aldığı, 15.226 kişinin hayatını kaybettiği ve 23.983 kişinin de yaralandığı görülmektedir.

## 2.5. Deprem Sonrası Binaların Hasar Tespiti

Afetlerin sebep olduğu hasarların tespiti için birçok yöntem kullanılmaktadır. Uzaktan algılama teknolojisi sayesinde de afet riskini azaltmak, afete hazırlıklı olmak, müdahale etmek ve araştırmaları iyileştirmek için doğru ve etkili analizlenen uygulama yöntemleri geliştirilmektedir.

### Şekil 8. Afet Sonrası Uzaktan Algılama Örneği



Kaynak: Pi vd., 2020: 5

AFAD afet öncesi ve sonrası uzaktan algılama teknolojilerinden faydalanarak “AYDES – UZAL” ve “AYDES – Kitle Kaynak” yazılımları geliştirmiştir. AYDES-UZAL; deprem, sel, heyelan, orman yangınları gibi afet türleri gerçekleşikten sonra etki ve hasar tespit analizleri için özelleşmiş uygulamaları içeren yazılımdır. Yazılımın temel amacı, afet öncesinde ve sonrasında elde edilen uzaktan algılama verilerinin işlenmesi, analiz edilmesi ve sonuçlarının afet yönetiminde kullanılan sistemlere aktarılmasıdır (AYDES Uzaktan Algılama (UZAL) (afad.gov.tr), 2020).

Afet sonrasında binaların hasar tespitlerine yönelik literatür taraması yapıldığında; coğrafi verilerinden faydalanarak uydu görüntülerinden, hava fotoğraflarından ve LIDAR nokta bulutunun kullanıldığı görülmektedir (Kayı vd., 2015: 227).

Deprem sonrasında binaların hasar tespitinde yüksek çözünürlüklü uydu görüntüleri ve hava fotoğrafları sıkça kullanılmaktadır. Yüksek konumsal ve geniş spektral çözünürlüklü hava fotoğrafları kalıcı kaydedilebilme özellikleri sayesinde daha çok tercih edilmektedir (Sümer ve Türker, tarih yok: 1).

G. Bitelli ve arkadaşları (2004) tarafından yapılan “Kentsel bölgelerde görüntü değişim analizi; Deprem örneği” adlı çalışmada depremde binaların hasar alıp almadıklarını tespit etmek için uydu görüntülerinden faydalanmışlardır. Çalışmada piksel tabanlı sınıflandırma ile yapılan aşamasında kullanılan uydu görüntülerindeki kayıklıklar nedeniyle verilerin uygun eşlemediği hatalı sonuçlar verdiği gözlemlenmiştir (Bitelli vd., 2004: 697).

Yukarıdaki örnekler gibi literatürde uzaktan algılama teknolojilerinden faydalanılarak gerçekleştirilen afet sonrası hasar tespit çalışmaları konusunda birçok çalışma incelenebilir. Bu tür çalışmalar her geçen gün daha da geliştirilip çoğaltılmaktadır.

## ÜÇÜNCÜ BÖLÜM

### 3. YAPAY ZEKA

#### 3.1. Yapay Zeka Kavramı

Günümüz dünyasına baktığımızda kendiliğinden kontrol edebilen araçlar, akıllı hoparlörler gibi birçok akıllı cihazlar, çeşitli görüntü tanımlayabilen nesneler görülmektedir. Yapay zekadaki ilerlemeler sayesinde dış verileri doğru şekilde yorumlayabilen ve bu tür verilerden öğrenebilen, öğrendiklerini belirli hedeflere ulaşmak ve verilen görevleri yerine getirmek için kullanabilen nesneler üretilmektedir. Yapay zeka (YZ) kavramı, 1956 yılında Marvin Minsky ve John McCarthy 'nin New Hampshire'da ki Dartmouth Koleji'nde yaklaşık sekiz haftalık Dartmouth Yaz Araştırma Projesi'ne ev sahipliği yaptığı dönemde ortaya çıkmıştır (Haenlein ve Kaplan, 2019: 1).

Yapay zeka kavramını tanımlamak çok fazla tartışma konusu ve karışıklığa neden olmuştur. Literatürde birçok yapay zeka tanımı vardır. Fakat bunların çoğu insanlar gibi düşünen sistemler, insanlar gibi davranan sistemler, rasyonel düşünen sistemler ve rasyonel davranan sistemler üzerine kategorize edilebilir. Örneğin, sözlüklerde yapay zekanın dört farklı tanımını görmek mümkündür.

- i. Bilgisayar bilimi alanında yapılan çalışmalar. Yapay zeka, bilgisayar sistemlerinin insan gibi öğrenme, düşünme, yorumlayabilme ve kendi kendine düzeltebilmesi için yapılan gelişim çalışmalarıdır.
- ii. Makinelerin, insan zekası gibi öğrenme, adaptasyon olma, kendini düzeltme vb. yeteneklerini geliştirebilen kavramdır.
- iii. Geçmiş zamanlardan beri insanlar fiziksel güçlerinin kapasitesini arttırmak için mekanik aletleri kullanması gibi bilgisayar sistemleri kullanarak insan zekası kapasitesinin genişletilmesidir.


- iv. Geliştirilmiş programlama teknik çalışmaları sayesinde bilgisayarları daha etkili şekilde kullanma tekniklerinin incelenmesidir (Kok vd., 2010: 1097)

Günümüzdeki önemini insanlara sağladığı avantajlar sayesinde ulaşan yapay zeka, insanların yaşamını kolaylaştırmak ve yaşam kalitesini arttırmak için kullanılmaktadır (Evrin, 2017: 3).

Yapay zeka, insanlara özgü olan öğrenme, algılama, düşünme, yorumlama ve çıkarım yapma gibi özellikleri makinelere kazandırılmasını sağlayan ve bu sayede makinelerin insan gibi düşünebilmesine, yorumlayabilmesine yardımcı olan bilgisayar yazılımlarının geliştirilmesidir (Görz, 2002'den aktaran Aydoğan ve Şener, 2020: 59).

Yapay zeka aktif olarak kullanıldığı birçok alanda ve çalışmalarda kolaylıklar sağlamaktadır. Robot gelişimi, akıllı asistanlar, dil bilimi, sağlık alanı ve ekonomi gibi alanlar bu alanlara örnek verilebilir (Yağcı vd., 2005: 35). Yapay zekanın kullanıldığı alanlardan bazıları Şekil 9. da verilmiştir.

**Şekil 9. Yapay Zekanın Kullanıldığı Alanlar**



Kaynak: Aydoğan ve Şener, 2020: 59

### 3.2. Yapay Zekanın Kısa Tarihi

Yapay zekanın tarihçesinin başlangıcı milat öncesine dayandırılmaktadır. Yunan mitolojisinde tanrıların kendilerine görevler yükledikleri yapay zeka ya da otomatlara rastlanmaktadır (McCorduck vd., 1977: 951).

Matematikçi ve bilgisayar bilim dalı uzmanı Alan Turing'in makine zekasının testi için ortaya çıkardığı Turing testi uygulamasıyla yapay zeka gerçek anlamda ortaya çıkmıştır (Mesko B., 2017'den aktaran Uzun T, 2020:81).

1950'lerde uzmanlar, insanlardan her yönüyle ayırt edilemeyen bilişsel, duygusal ve sosyal zekaya sahip olan yapay genel zeka sistemlerine ulaşmanın sadece birkaç yıl süreceğini öngördüler (Haenlein ve Kaplan, 2019: 1).

1990 yılında Ray Kurzweil teknolojiadaki ilerlemeleri gözlemleyerek 2000'li yıllar için şöyle tahminlerde bulunmuştur:

- i. Sanal gerçeklik üretmek için görüntüleri kullanıcıların retinalarına ışınlayan gözlükler (proje camı).
- ii. Günlük görevlerde yardımcı dokunabilecek sanal asistan programı içeren bilgisayarlar (Siri, Cortona).
- iii. Giysilere yerleştirilebilen ve sesi doğrudan kullanıcıların kulaklarına yansıtabilen cep telefonları (elektronik tekstil).
- iv. 2029 bilgisayarları, makinelerin bir insan gibi davranmasının ne kadar iyi olduğunu ölçebilecek Turing testini kolaylıkla geçebilecektir.
- v. 2045 yılında insanların makineler sayesinde gezegendeki belki de evrendeki en akıllı ve baskın türler olarak teknolojik tekilliğe sahip olacaktır (Yampolskiy & Spellchecker, 2016: 2).

N. Dalamater (2018), kitabında yapay zekanın kısaca tarihçesini incelemiş ve tablo şekline getirmiştir.

**Tablo 7. Yapay Zekanın Kısaca Tarihçesi**

<b>Antik Çağ</b> <ul style="list-style-type: none"><li>Antik çağlarda “robot” terimi ortaya çıkmasada, birçok efsanede bu terimle ilgili kavramsallaştırmalar ve insan benzeri eserler görülmektedir.</li></ul>
<b>13. Yüzyıl</b> <ul style="list-style-type: none"><li>1206 - Arap mucit El Cezari tarafından ilk insansı robot oluşturuldu.</li></ul>
<b>15. Yüzyıl</b> <ul style="list-style-type: none"><li>1440 yıllarında Johannes Gutenberg tarafından matbaa icat edildi.</li><li>1495 yılında, Leonardo da Vinci robot tasarladı.</li></ul>
<b>16. Yüzyıl</b> <ul style="list-style-type: none"><li>İlk ölçüm makinesi olarak saat icat edildi.</li></ul>
<b>17. Yüzyıl</b> <ul style="list-style-type: none"><li>Blaise Pascal ve Sir Samuel Morland tarafından dijital ve aritmetik hesaplamalar yapabilen makineler icat edildi, bu makineler sonrasında Gottfried Wilhelm Leibniz tarafından geliştirildi.</li></ul>
<b>19. Yüzyıl</b> <ul style="list-style-type: none"><li>Joseph-Marie Jacquard tarafından ilk programlanabilir makine olan Jakarlı tezgah icat edildi.</li></ul>
<b>20. Yüzyıl</b> <ul style="list-style-type: none"><li>1912 - Torres y Quevedo tarafından elektromıknatıslar tarafından işletilen satranç makinesi icat edildi.</li><li>1920 -İlk “robot” terimi, Çek oyun yazarı Karel Capek tarafından “Rossum’un Evrensel Robotları” oyununda kullanıldı.</li><li>1939 - Westinghouse Electricat, 1939 Dünya Fuarında “mekanik adam” tanıtıldı.</li><li>1945 - George Polya’nın tarafından yazılan “Nasıl Çözülür” kitabında “sezgisel düşünme” kavramına değinildi ve kavramının yapay zekanın arkasında ki bilimimi büyük ölçüde etkilediği söylenildi.</li><li>1950 - Amerikalı yazar Isaac Asimov tarafından üç robot yasası yayınlandı.</li><li>1956 - John McCarthy tarafından “yapay zeka” terimi icat edildi.</li><li>1956 - JC Shaw ve Herbert Simon tarafından ilk fonksiyonel yapay zeka programı Allen Newel yazıldı.</li><li>1957 - Athur Samuel, dama öğretebilen ve dünya şampiyonuna meydan okuyabilen ilk oyun oynama programı yazdı.</li><li>1962 - İlk endüstriyel robot şirketi olan Unimation şirketi kuruldu.</li><li>1963 -1971 - birkaç bilim insanı tarafından bilgisayarların aynı tür anolojileri, problemleri çözebileceği ve aynı dili anlayabileceğini keşfettiler.</li><li>1973 - ilk cep telefonu araması yapıldı.</li><li>1976 - Apple 1 piyasaya çıkarıldı.</li><li>1980 - Lisp makineleri piyasaya çıkarıldı.</li><li>1981- Danny Hill bağlantı makinesini tasarladı.</li><li>1989 - Word Wide Web oluşturuldu.</li><li>1992 - IBM, ilk “akıllı telefon” olarak kabul edilen Simon Personel Communicator icat edildi.</li></ul>
<b>21. Yüzyıl</b> <ul style="list-style-type: none"><li>2007 - Apple Iphone piyasaya sürüldü.</li><li>2010 - Apple, ses tanıma ve yapay zeka teknolojisini kullanarak oluşturduğu kişisel asistan “Siri” yi tanıttı.</li></ul>

Kaynak: Delamater N., 2018: 3

### 3.3. Yapay Zekanın Alt Dalları

Yapay zeka, sergilediği zeka türüne göre (bilişsel, duygusal ve sosyal zeka) veya evrimsel aşamasına göre analitik, insandan ilham alan ve insanlaşmış yapay zeka olarak sınıflandırılabilir (Haenlein ve Kaplan, 2019: 2).


Yapay zeka yapay sinir ağları, uzman sistemler, genetik algoritmalar, bulanık mantık gibi birçok alt daldan ve bu alt dalların bir arada görüldüğü çeşitli kombinasyonlardan oluşan dallardan oluşur.

- a) **Uzman sistemler:** Uzman seviyesinde ki insan bilgisini makineler tarafından uygulanabilir hale getirmeye çalışılan tekniktir. (Teşhis- Süreç kontrol- Tıp- Telekomünikasyon vb.)
- b) **Bulanık mantık:** Karmaşık ve kesin olmayan sistemleri modelleme aşamalarında kullanılan tekniktir. Bulanık küme elemanları, 0 ile 1 aralığında fonksiyon kullanarak bir üyelik değerleri evrenine eşlenir. (Robot kolları- Otomasyon ve akıllı kontrol sistemleri- Oto elektroniği, fren sistemleri- Akıllı bina sistemleri- Akıllı ev otomasyonları vb.)
- c) **Genetik algoritma:** Doğal seleksiyon ve en uygun olanın hayatta kalmasına dayanan optimum arama tekniğidir (Mellit vd., 2009: 407). (Haberleşme şebekleri tasarımı- Elektronik devre dizaynı- Görüntü ve ses tanıma- Veri tabanı sorgulama optimizasyonu- Uçak tasarımı)
- d) **Hibrit sistemler:** Bulanık mantık ve sinir ağları gibi iki veya daha fazla sistemin bir arada kullanıldığı tekniktir (Mellit vd., 2009: 408-410).
- e) **Dalgacık dönüşümü:** Sinyal işleme gibi uygulamalarda kullanılan sinyal dönüşüm tekniğidir (Aydın ve Aslan, 2017: 752)
- f) **Yapay sinir ağları:** Makinelerin insanlar gibi eğitilmesi, öğrenebilmesi ve yorumlar yapabilmesi için uygulanan tekniktir (Aydoğan ve Şener, 2020: 62). Yapay sinir ağları, beynin basit bir nöron modelinin benzetimidir. Bu sayede elde edilen ağ ile makinenin öğrenme işlemi gerçekleşir. Kontrol ve sistem tanımlama, tahmin ve kestirim, görüntü ve ses tanıma, trafik, üretim yönetimi, tıp, arıza analizi gibi alanlarında yapay sinir ağlarından faydalanılmaktadır (Pirim, 2006: 87). (Robotik uygulamaları- Görüntü tanıma- Ses tanıma- Robot ve kontrol sistemlerini otomatikleştirme- İmalat kalite kontrolü- Üretim işlem kontrolü vb.)

g) **Makine Öğrenmesi**; bilgisayarları yeni yollarla eğitmenin olanaklarını keşfetmeyi amaçlamaktadır (Carbonell ve Mitchell, 1983: 4)

Yapay zeka teknolojileri geliştirilirken farklı çalışma alanlarından faydalanılmaktadır. Birçok alt dallardan oluşmaktadır. Bazı alt dallar Şekil 10'da gösterilmektedir.

**Şekil 10. Yapay Zekanın Alt Dalları**



Kaynak: Aydoğan ve Şener, 2020: 59

### 3.3.1. Makine Öğrenmesi

Makineler, gelecekteki veriler hakkında tahminler yapmak ve bu tahminler doğrultusunda rasyonel kararlar almak için önceden eğitilmiş modeller kullanabilir. Makinelerin eğitilmesi ve geliştirilmesi için oluşturulan modeller yapay zekanın alt dalı olan makine öğrenmesi alanında incelenmektedir (Ghahramani, 2015: 452).


Makine öğrenimi, sürekli gelişmekte olan bilgisayarların nasıl oluşturulacağı sorununu ele almaktadır. Yapay zeka ve veri biliminin merkezinde yer alan günümüzün en hızlı büyüyen teknik alanlarından biridir. Makine öğrenmesinde ki son gelişmeler, hem yeni öğrenme algoritmaların hem de teorilerin geliştirilmesinde çevrimiçi verilerin kullanılabilmesi ve düşük maliyetli hesaplamalar yapılabilmesi sayesinde gerçekleşmiştir (Jordan ve Mitchell, 2015: 255).



Makine öğrenmesi başlıca;

- Perakende, finans ve banka analizleri,
- Kredi kartı dolandırıcılığı tespitleri,
- Üretim alanında optimasyon, kontrol ve arıza tespitleri,
- Tıp alanında medikal tanı tespitleri,
- Telekomünikasyon alanında, çağrı düzeninde ağı optimize etmek ve hizmet kalitesini en üst düzeye çıkarma çalışmalarında,
- Fizik, biyoloji ve astronomi gibi büyük verilerin bilgisayarlar tarafından yeteri hızda analiz edilmesi,
- Ses tanıma, vizyon ve robotik problemleri çözümü gibi çalışmalarda kullanılmaktadır (Alpaydın, 2020: 3).

#### Şekil 11. Makine Öğrenmesinden Faydalanılan Bazı Alanlar



Kaynak: Jordan ve Mitchell, 2015: 256

Makine öğrenmesi, üç ana alanın çevresinde örgütlenmektedir. Bu alanlar;


- Görev odaklı çalışmalar; önceden belirlenmiş görevler doğrultusunda performansı arttırmak için öğrenme sistemlerinin geliştirilmesi ve analizidir.

- Bilişsel simülasyon; insanın öğrenme süreçlerinin araştırılması ve bilgisayar ortamına taşınmasıdır.
- Teorik analiz; olası öğrenme yöntemleri ve algoritmaların, uygulama alanından bağımsız şekilde, teorik olarak araştırılmasıdır (Carbonell ve Mitchell, 1983: 4).

Makine öğrenmesinde yöntemler, temel sınıflara ayrılarak incelenmektedir:

- Öğreticili (supervised) yöntemler:** Gözetimli ya da denetimli öğrenmedir. Modele veriler hakkında ön bilgiler verildiği ve bu bilgiler doğrultusunda analizleme istenildiği yöntemdir.
- Yarı-öğreticili (semi-supervised) yöntemler:** Yarı gözetimli ya da yarı denetimli öğrenmedir.
- Öğreticisiz (unsupervised) yöntemler:** Gözetimsiz ya da denetimsiz öğrenmedir (Onan ve Serdar, 2016: 111). Modele herhangi bir bilgi verilmeden, modeli önceden eğitmeden direk veriler üstüne kendi kendine öğrenmesi amaçlanan yöntemdir (Wu vd., 1992: 652).
- Takviye (reinforcement) yöntemler;** bu yöntemde bilgisayar programının belirli bir hedefi gerçekleştirmek için dinamik ortama erişimi sağlanır (Shailaja vd., 2019: 910).
- Çoklu görev (multitask) öğrenme yöntemleri;** diğer yöntemlerin daha iyi performans sağlamasını sağlayan yardımcı yöntemdir.
- Grup (ensemble) öğrenme yöntemleri;** farklı makineler tek bir makine oluşturmak için birleştikleri yöntemdir.
- Güçlendirme;** yanılmayı ve varyansı azaltmak için kullanılan tekniktir. Zayıf makineleri güçlü makinelere çevirir.
- Sinir ağı (neural network) öğrenme yöntemleri;** veriler biyolojik nöron gibi öğrenip yorumlayan yöntem tekniğidir.
- Örnek tabanlı (instance-based) öğrenme yöntemleri;** makine belirli desen türünü öğrenir. Yeni verilere aynı deseni uygulamaya çalışır (Dey, 2016: 1178-1179).

**Tablo 8. Makine Öğrenmesi Sınıflandırma Teknikleri**



### 3.3.1.1. Derin Öğrenme

Derin öğrenme (deep learning) terimi, ilk olarak 2000 yılında Igor Aizenberg ve arkadaşları tarafından tanıtılmış olsa da 2006'dan bu yana, makine öğrenmesinin yeni bir alt dalı olarak yaygınlaşmıştır. Derin öğrenme, özellik çıkarma ve dönüştürme için çok katmanlı doğrusal olmayan işlem birimleri kullanılır. Her katman, kendinden önceki katmanın çıktısını girdi olarak alır. Derin öğrenme algoritmaları, denetimsiz veya denetimli öğrenme tekniklerinden faydalanır (Deng ve Yu, 2013: 198).

Derin öğrenme, günümüzde çok popüler olmakla birlikte yapay zeka ve makine öğrenmesinin önemli bir alt dalıdır. Derin öğrenme yöntemleri genellikle yapay sinir ağı (YSA) araştırmasında geliştirilir. Derin öğrenme yöntemleri, ham verilerden verimli üst düzey soyutlamalar gerçekleştirerek otomatik özellik kümeleri oluşturabilir. Böylece genellikle insanlar tarafından belirlenen özellikler otomatik olarak çıkarılabilir ve kullanılabilir (Ravi vd. 2017: 4).

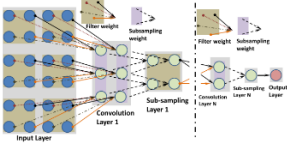
Derin öğrenme yöntemleri; birden çok veri türünün (video, ses, metin gibi) işlenmesinde oldukça başarılı sonuçlar elde etmiştir. Genel olarak bir yöntem, doğal dil işleme gibi metin verilerinin işlenmesinde başarıya ulaşırken, başka bir yöntem video ve ses verilerinin işlenmesinde daha başarılı sonuçlar elde edebilir. Bazı çalışmalarda ise kullanılacak olan derin öğrenme yöntemi birden çok modu (aynı anda metin, görüntü ve ses gibi farklı modlar) öğrenme için başarıyla kullanılabilir (Küçük ve Arıcı, 2018: 77) (Weston ve Collobert, 2008: 160).

### 3.3.1.1.1. Derin Öğrenme Mimarileri

Tablo 9’da görüldüğü gibi derin öğrenme algoritmalarında kullanılacağı alana göre, kullanmış olduğu katman sayılarına göre, girdi ve çıktıları işleme biçimine göre çeşitli mimariler bulunmaktadır.

**Tablo 9. Derin Öğrenme Mimarileri**

Mimari Yapısı	Derin Öğrenme Yöntemi	Özellikler
	Derin Sinir Ağları	<ul style="list-style-type: none"> <li>- Genellikle sınıflandırma ve regresyon için kullanılır.</li> <li>- Birçok gizli katmandan oluşur.</li> <li>- Karmaşık hipotezlerin ifade edilmesini sağlar.</li> </ul>
	Derin Otomatik Kodlayıcılar	<ul style="list-style-type: none"> <li>- Esasen özellik çıkarımı veya boyutsallık azaltma için tasarlanmıştır.</li> <li>- Aynı sayıda girdilere ve çıktılara sahiptir.</li> <li>- Giriş vektörünü yeniden oluşturmayı amaçlamaktadır.</li> <li>- Denetimsiz öğrenme yöntemi kullanılır.</li> </ul>
	Derin İnanc Ağları	<ul style="list-style-type: none"> <li>- Her bir alt ağı gizli katmanının bir sonraki için görünür katman görevi gördüğü bir RBM bileşimidir.</li> <li>- Denetimli ve denetimsiz eğitim yöntemi kullanımına izin verir.</li> </ul>
	Derin Boltzmann Makinesi	<ul style="list-style-type: none"> <li>- Ağı tüm katmanları arasında yönlendirilmemiş bağlantılara sahiptir.</li> <li>- Olasılığın en alt seviyesini en üst düzeye çıkarmak için stokastik bir maksimum olasılık algoritması kullanır.</li> </ul>
	Yinelenen Sinir Ağları	<ul style="list-style-type: none"> <li>- Veri akışını analiz edebilen sinir ağıdır.</li> <li>- Çıktının önceki hesaplamalara bağlı olduğu uygulamalarda kullanışlıdır.</li> <li>- Tüm adımlarda aynı ağırlıklar paylaşılır.</li> </ul>

	<p style="text-align: center;"><b>Evrişimsel Sinir Ağları</b></p>	<ul style="list-style-type: none"> <li>- Görüntü gibi iki boyutlu veriler için uygundur.</li> <li>- Her gizli evrişimli filtre, girdilerini üç boyutlu nöron aktivasyonuna dönüştürür.</li> <li>- Görsel korteksin nörobiyolojik modelinden esinlenilmiştir.</li> </ul>
---	---	---


Kaynak: Ravi vd., 2017: 7

### 3.3.1.1.2. Evrişimli Sinir Ağları

Evrişimli sinir ağları (convolutional neural network-CNN), çok katmanlı algılayıcılara sahip derin öğrenme mimarisidir. Evrişimli sinir ağları, ileri yönlü bir sinir ağı olup hayvanların görme yeteneğinden esinlenerek ortaya çıkmıştır. Evrişimli sinir ağı algoritmaları, doğal dil işleme, biyomedikal, görüntü ve ses işleme gibi bir çok alanda uygulanmaktadır.(Şeker vd., 2017: 50).

Evrişimli sinir ağlarının literatürde birçok farklı versiyonu bulunmaktadır ve bu sinir ağları diğer sinir ağlarından daha az nöron bağlantısına sahiptir. Öğrenme aşamasında oldukça büyük boyutlu verilere ihtiyaç duyarlar (Ravi vd., 2017: 9). Evrişimli sinir ağları, çok katmanlı sinir ailesinden olup daha çok görüntü ve video gibi 2 boyutlu veriler için tasarlanmışlardır. Evrişimli sinir ağlarında görüntünün küçük bölümleri hiyerarşik yapının en alt katmanını girdi olarak kabul edilir. Katmanlar arasında ki anlamlı ve uyumlu ilişkiler görüntü işleme ve anlama için elverişli hale getirmekte, görüntülerde ki göze çarpan özellikleri algılamakta iyi performans sergilemesini sağlamaktadır (Arel vd., 2010: 14, 15).


**Şekil 12. Evrişimli Sinir Ağının Kavramsal Örneği**



Kaynak: Arel vd., 2010: 14

Evriřimli sinir aęları, ok katmanlı model olup son katman olan ıkıř katmanında veriye (grnt vb.) ait zellik haritaları belirlenir. İlk katmanlarda, verinin daha basit zellikleri bilgileri tespit edilirken, sonraki katmanlarda nceki katmanlardan elde edilen bilgiler doęrultusunda verinin geneline ait zellikleri belirlenmektedir. Evriřim sreci, sinir hcrelerinin kendi uyarı alanlarındaki uyarıma vermiř olduęu tepkinin modellenmesi olarak dřnlebilir (Beřer vd., 2018: 2).

**řekil 13. Evriřimli Sinir Aęının Kavramsal rneęi**



Kaynak: Kurt, 2018: 6

Temel yapısı nedeniyle, evriřimli sinir aęının standartlařtırılmıř, standart boyutlu bir giriř katmanı (grnt almak iin kullanılır), bir ara katman (bir dizi evriřim ve alt rnekleme iřlemi gerekleřtirmek iin kullanılır) ve tamamen baęlı bir aędan oluřan bir ıktı katmanı vardır. Evriřimli sinir aęı mimarisinin en nemli zellięi, bir katmandaki her dęmn, nceki katmanın sınırlı alanından girdi almasıdır (Lecun vd., 1998: 2279).

Evriřimli sinir aęları ok byk verilerle alıřabilmesi sayesinde nemli geliřmeler gstermiř ve son yıllarda kullanımı yaygınlařmıřtır. Uydu grntlerinden saęlanan resimler, videolar gibi yksek boyutlu veriler ile yapılan alıřmalar evriřimli sinir aęları sayesinde yksek doęruluk oranına ulařmaktadır. Yeni nesil evriřimli sinir aęları algoritmaları, yksek miktarda veri ve performansı yksek GPU'lar sayesinde teknoloji devriminde yeni bir sayfa aılmıř bylelikle de gnmzde kendini kontrol edebilen aralar ve robotlar grebilmekteyiz (Muhammad vd., 2018: 1622).

### 3.3.1.1.2.1. Evrişimli Sinir Ağı Mimarileri

Sinir ağı modellerinin kullanımı için genellikle mimariler gerekmektedir. AlexNet, Resnet, ZFNET, VGGNet ve NasNet gibi mimariler örnek verilebilir (Zoph vd., 2018: 8697).

Tipik bir evrişimli sinir ağı mimarisi aşağıdakilere sıralamaya göre çalışmaktadır;


- i. Birinci katman, giriş verilerini temsil eder ve tanımlama işlevi olarak kullanılır ve bu katman işlem gerektirmez,
- ii. İkinci katman aktivasyon fonksiyonu ile üst üste bindirme işleminden ve hesaplamadan sorumludur,
- iii. Üçüncü katman ise havuzlama işlemi yoluyla alt örnekleme uygular (ikinci ve üçüncü katmanlar tekrarlanabilir katmanlardır),
- iv. Son katman çıktı özelliklerini vermektedir (Lecun vd., 2015: 439).

Genel olarak evrişimli sinir ağı mimarileri girdi, evrişim, havuzlama, tam bağlaşımlı ve çıktı katmanları olmak üzere beş ana katman kullanılmaktadır (Peemen vd., 2016: 1605). Bazı çalışmalarda ve mimarilerde daha fazla katman kullanılmaktadır (Ferreira vd., 2018: 8).

- a. **AlexNet Ağı Mimarisi;** sekiz katmandan oluşmaktadır. İlk beş katman evrişim için kullanılır, diğer üç katman ise tam bağlaşımlı katman oluşturmak için kullanılır.
- b. **ZFNET Ağı Mimarisi;** AlexNet mimarisinin evrişim yapısını gibi sekiz katmanlıdır. Bu mimari de orta katmanlarda uygulanan filtre boyutları büyütülürken, ilk katmanda ki filtre boyutu düşürülür.
- c. **Resnet Ağı Mimarisi;** Microsoftun oluşturmuş olduğu mimaridir.
- d. **GoogleNet Ağı Mimarisi;** Google tarafından oluşturulmuş mimaridir (İnik ve Ülker, 2017: 97,98).
- e. **VGGNet Ağı Mimarisi;** (visual geometry group network - görsel geometri grup ağı) AlexNet ağı ile benzer prensiplere göre üretilmiştir (Muhammad vd., 2018: 1623). VGGNet mimarisinin VGG-16 ve VGG-19 gibi çeşitli sürümleri bulunmaktadır.


- **VGG-16;** Oxford Üniversitesinde Görsel Geometri Grubu tarafından geliştirilen derin öğrenme algoritmasıdır. Mimari, 13 konvolüsyon ve 3 tam bağlı katmandan oluşan ağıdır. Girdi olarak kullanılan görüntüler 224x224x3 boyutunda olurlar. Son katmanı sınıflandırma katmanı olarak kullanır (Doğan ve Türkoğlu, 2018: 16).

**Şekil 14. VGG-16 Mimarisi**



- **VGG-19;** Oxford Üniversitesinde Görsel Geometri Grubu tarafından geliştirilen derin öğrenme algoritmasıdır. Mimari, 16 konvolüsyon ve 3 tam bağlı katmandan oluşmaktadır. Girdi olarak kullanılan görüntüler 224x224x3 boyutunda olurlar. Son katmanı sınıflandırma katmanı olarak kullanır (Doğan ve Türkoğlu, 2018: 16).


**Şekil 15. VGG-19 Mimarisi**





- **NASNet**; (neural architecture search (NAS) - sinir mimarisi arama) mimari yapıları optimize etmek için yeniden güçlendirme ve öğrenme arama yöntemini kullanan nöral mimaridir (Zoph vd., 2018: 8697).

### Şekil 16. Evrişimli Ağ Mimarisinin Uygulama Örneği



Kaynak: Lecun vd., 2015: 438

Yukarıdaki şekilde Tipik bir evrişimli ağ mimarisinin her katmanının (yatay olarak) çıkışları bir Samoyed köpek görüntüsüne uygulanışı (sol alt; ve RGB (kırmızı, yeşil, mavi) girişleri, sağ alt) gösterilmiştir. Her dikdörtgen görüntü, görüntü konumlarının her birinde tespit ederek öğrenilen özelliklerden birinin çıktısına karşılık gelen bir özellik haritasıdır (Lecun vd., 2015: 438).

#### 3.3.1.1.3. Görüntü Segmentasyonu


Görüntü segmentasyonu, görüntü analizi ve örüntü tanıma sisteminin ilk ve en önemli bileşenidir. Görüntü segmentasyonu, görüntüyü farklı bölgelere ayırma işlemidir. Genel olarak görüntüdeki nesneleri ve görüntünün sınırlarını anlamlandırma işine yarar. Görüntü işlemede en karmaşık ve analiz sonucunun kalitesini belirleyen aşama görüntü segmentasyonu aşamasıdır (Cheng vd., 2001: 2259) (Küçükkülahlı vd., 2016: 1445).

Genel olarak görüntü segmentasyonu işleminde görüntünün bölgeleri gri ton veya doku gibi özelliklere göre düzgün ve homojen dağılmaktadır. Görüntü segmentasyon teknikleri; ölçüm alanı güdümlü mekansal kümeleme şemaları, tek bağlantı bölgesi yetiştirme şemaları, hibrit bağlantı bölgesi yetiştirme şemaları, kitle merkezli bağlantı

bölgesi yetiştirme şemaları, mekansal kümeleme şemaları ve bölme-birleştirme şemaları olarak sınıflandırılabilirler (Haralick ve Shapiro, 1985: 100).

Görüntü segmentasyonunda geçmişte gri tonlamalı segmentasyon yöntemleri kullanılsa da günümüzde renkli görüntü segmentasyon yöntemleri geliştirilmiştir ve günümüzde bu yöntemler daha yaygın kullanılmaktadır. Renkli görüntü segmentasyonu, renkli segmentasyon tekniğinin fazla bilgi barındırabilmesi ve teknolojinin gelişmesiyle birlikte bilgisayarların renkli görüntüler üzerinde hızlı çalışabilmesi sayesinde araştırmacıların ilgisini çekmeye başlamış olup daha çok tercih edilir olmuştur (Cheng vd., 2001: 2259).

**Şekil 17. Gri Tonlu Görüntü Segmentasyonu**



Kaynak: Yanowitz ve Bruckstein, 1989: 94

Görüntü segmentasyonu tekniklerinde denetimli (öğretimli) ve denetimsiz (öğretimsiz) olmak üzere iki yaklaşım vardır. Denetimsiz yaklaşımda, görüntüdeki sınıfların özellikleri ve sayıları önceden bilinmez, segmentasyon işleminde belirlenen benzerlik ölçütleri kullanılır. Denetimli yaklaşımda ise görüntüdeki sınıfların özellikleri ve sayıları önceden bilinir, bu bilgiler segmentasyon işlemlerinde kullanılır (Lillesand ve Kiefer, 1994'den aktaran, Bedük, 2011: 16).

Görüntü segmentasyon algoritmaları içerisinde çeşitli algoritma türlerini barındırmaktadır. Bu algoritmalar arasında en yaygın kullanılan algoritma türü K-means algoritmasıdır. Bu algoritma aynı zamanda Lloyd algoritması olarak da adlandırılır. Bu

algoritma kümeleme işlemi sırasında belirli küme numarasına ihtiyaç duyar (Akhan vd., 2018: 176)

K-means algoritması, başlangıçta küme merkezlerini rastgele veya belirli yollarla seçer. Bir küme merkezi, onu kapsayan ilgili kümeyi temsil eder. K-means algoritması, yinelemeli ilerleme sağlar. İlk yinelemede, tüm verilerdeki her öge, küme merkezlerine olan yakınlığına göre bir kümenin üyesi olur. Bir sonraki yinelemede, her küme merkezi, kümedeki öğelerin ortalama özellik değerini dikkate alarak yeniden hesaplanır. Küme merkezlerinin hesaplanmasından sonra, verideki her ögenin tanımlamaları yeni küme merkezlerinin değerlerine göre güncellenir. Küme merkezlerinde herhangi bir değişiklik yoksa, algoritma sona erer (Jain vd., 1999: 279).

### **3.4. Afet Alanında Yapay Zeka Kullanımı**

Afet yönetimi alanında büyük verilerin kullanıldığı çalışmalarda artış gözükmemektedir. Büyük verilerin kullanımıyla afet yönetiminde yapay zeka, makine öğrenmesi gibi alanlardan da faydalanılmaya başlanılmıştır. Deprem, sel, kasırga gibi birçok afet türlerinde afet yönetiminin farklı farklı aşamalarında yapay zeka ve alt dalları kullanılmaktadır. Büyük veriler oluşturan insansız hava araçları, uydu görüntüleri, internetli nesneler, sensörler, uzaktan algılama, sosyal medya, GPS, mobil vb. gibi nesneler, uygulamalar yapay zeka ile kullanılabilir hale getirilerek afet yönetiminde kullanılabilirler (Yu vd., 2018: 2).

Son yıllarda teknolojinin hızla gelişmesiyle nesnelerin internete bağlanabilmesi ve internet kullanımı yaygınlaşmıştır. Nesnelerin interneti kullanabilmesiyle artan kullanım özellikleri yapay zekayla desteklenerek geliştirilmektedir. Bu gelişim tarım, endüstri, eğlence, sağlık gibi alanlara büyük avantajlar sağladığı gibi afet yönetimi alanında da zarar azaltma aşamasında risklerin belirlenip azaltılması, müdahale aşamasında hasar tespiti, kolay müdahale ve iyileştirme çalışmalarında büyük avantajlar sağlamaktadır (Sinha vd., 2019: 763). İnternet kullanabilen nesnelerin kullanım alanları incelendiğinde deprem, volkan, orman yangınları vb. gibi farklı afet türlerinin afet yönetimi alanlarında da kullanıldığı görülebilmektedir (Ray vd., 2017: 18825).

**Tablo 10. İnternet Kullanabilen Nesnelerin Afet Alanında Kullanım Örnekleri**

Uygulama	Amaç	Afet türü
Makine Öğrenmesi ve Yapay Zeka Etkinleştirimi	Volkan Püskürmelerini Öngörme	Volkan
WSN	Radio İletişimi	Volkan
GIS Birleşimi	Hasar ve Destek Kararı Almak İçin Öngörü Ölçütlendirmesi	Volkan
Ölçeklenebilir, Güvenilir ve Verimlilik Tasarımı	WSN yi güçlendirme	Sel
M2M ve Ultra-Düşük Güç İşlemci	Düşük maliyetli algılama ve mesajla uyarı sistem ağı oluşturmak	Sel
Netduino Plus 2	Su seviyesinin görüntülenmesini WiFi ile entegre etme	Sel
Erken Algılama SMS Servisi	Mesajlar sayesinde insanların uyarılmasını kolaylaştırmak	Sel
CCTV ve Makine Öğrenmesine Bağlı Görsel Görüntüleme	Görüntü İşleme Kullanarak Gerçek Zamanlı Taşkın İzleme	Sel
Orman Hava Durumu Endeksi	Orman yangınlarını karar vermek için algoritmalar oluşturmak	Orman Yangınları
OPENMTC ve M2M İletişimi	Ormanlara yerleştirilen sensörler arası iletişim sağlama	Orman Yangınları
Yağış Kaynaklı Heyelan Yönetimi INSAT 3A Uydu Görüntüleri	Heyelanlarını yerel verilerini uydu bağlantılarıyla izlemek yönetmek	Heyelan
Heyelan Öncesi Akustik Sensörlü Algılayıcı Kullanımı	20-30 KHz frekans aralığını düşürerek ölçmek	Heyelan
İvmeölçer ve HSPDA Modem	Afet verilerini toplamak ve analiz etmek	Heyelan
NerveNet Ağ Atlama	Topolojiden bağımsız, esnek veri aktarım aracı sağlamak	Deprem
Zigbee ve PIC Mikro Kontrollere Dayalı Erken Uyarı Sistemi	P ve S dalgalarını ölçmek ve insanları uyarmak	Deprem
Novel Sistem Modeli	Bütünleşik yönetimin planlanması	Deprem
Seans Başlatma Protokolü	Erken uyarı sistemi için sistem geliştirmek	Deprem
Scale Taslağı	Esnek veri aktarımının ölçeklenebilirliğini sağlamak	Deprem
SSN Deprem Tehlikesi Yönetimi	Ontoloji tabanlı altyapıda meta veri işlemlerini sağlamak	Deprem
Sosyal Farkındalık	Sosyal davranışın afet durumlarında tahmini	Kent Felaket

Kent Yeraltnın Ekosisteminde Afet Yönetimi	Yeraltı ekosistem güvenliğinin yönetimi ve geliştirilmesi	Kent Felaket
VANET Kaza Görüntüleme	Kazaların tahmini, önlenmesi, tıbbi müdahale ekiplerinin uyarılması	Kent Felaket
Mikro Drone Görüntüleme	Mikro drone ile gaz kaçaklarının tespiti	Gaz Endüstrisi
Hata Tespiti Sistem Modeli	Proses endüstrisinde hata tespitlerini bulma	Gaz Endüstrisi
Güvenlik Görüntüleme	Çapraz Platform bilgi sistemi tasarlamak	Kömür madeni
SVM Sınıflandırma ve FASTSLAM	Robotlar kullanarak kurtarma ekiplerine afetzedenin hakkında bilgiler ulaştırma	Lokalizasyon
K-Out-Of-K Füzyon Kuralı	Afetzedeleri kurtarmak için Gauss gürültüsüyle bozulmuş zayıf sinyalleri güçlendirmek	Lokalizasyon
RFID Kümeleme	Yakınındakilerle iletişim kurabilmek	Lokalizasyon
Füzyon Hibrit Kuralı	RSSI tabanlı sinyallerin başarısızlığında RFID okumalarını algılayabilmek	Dinamik Lokalizasyon
Uygulanabilir Sinyal Eşikleme	Kişinin hareketine göre sinyal kaynaklarıyla eşleşebilme	Lokalizasyon
Topoloji Koruma Haritası	Topoloji Koruma Haritalarını, küçük ve bilinmeyen koordinatlardan tahmin etmek	Lokalizasyon
FM Entegrasyon	Bozuk ses sinyalleri arasında çapraz korelasyon gerçekleştirerek afetzedelerin yerinin tespiti	Lokalizasyon

Kaynak: Ray vd., 2017: 18825

Günümüzde yaygınlaşan sosyal medya kullanımı afet yönetiminde de büyük önem kazanmıştır. Sosyal medyadaki paylaşımlar sonucu oluşan büyük veriler sayesinde risklerin belirlenmesi, erken uyarı sistemlerin geliştirilmesi, kurumlar ve toplum arasındaki iletişim kurulabilmesi ve afet anında afet bölgesindeki hareketliliği analiz edebilme imkanları ortaya çıkmaktadır (Memiş ve Babaoğlu, 2020: 169). Afet bölgesinde olmayan kişiler afet bölgesinde bulunan kişilerin paylaşımları sayesinde afetin vermiş olduğu hasar boyutları ve afet bölgesi hakkında detaylı bilgilere ulaşabilmektedirler (Landwehr ve Carley, 2014: 226).

**Tablo 11. Afet Alanında Kullanılan Ürün ve Uygulama Örnekleri**

Ürün - Uygulama	Amacı	Afet Türü
Brinco	Deprem ve tsunami anında toplumu kişisel olarak bilgilendirmek.	Deprem ve Tsunami
Brck	İletişim araçlarının ve internet ağının olmadığı veya hasar gördüğü bölgelerde 2G ile iletişim sağlayabilmek.	Birçok tür
Grillo	Olası sismik hareketliliğinde insanları uyarıda bulunmak.	Deprem ve Tsunami
Sel ağı	Dünya çapında sel algılama ağı kurabilmek.	Sel
Sel Uyarıcısı	Mevcut su seviyelerinin internet üzerinden anlık olarak ilgili birimlere aktarmak.	Sel ve Tsunami
Gezici Sensör Ağı	Yüzen nesneleri kullanarak nehirlerin sel durumu hakkında bilgiler toplamak ve öngörülerde bulunmak.	Sel ve Tsunami
Yıldırım Algılayıcı	Yıldırım kaynaklı ölüm oranını düşürmek.	Yıldırım
ALARMS	Gerçek zamanlı akustik izleme sistemleri (alarmlar) kullanarak heyelan değerlendirmelerinde bulunmak	Heyelan
MyShake	Sismik faaliyetlerin tespiti için uygulama tabanlı hizmettir.	Deprem

Kaynak: Ray vd., 2017: 18823

Yukarıda ki tabloda yapay zekanın sağladığı avantajlardan faydalanılarak afetlerde kullanılmak üzere çeşitli uygulama örnekleri verilmiştir. Bu uygulama örnekleri daha da geliştirilip çeşitlendirilmelidir.

## **DÖRDÜNCÜ BÖLÜM**

### **4. GEREÇ VE YÖNTEM**

#### **4.1 Problemin Durumu**

İnsanlığın varoluşundan beri afetler ve felaketler insanlığa en çok zarar veren nedenler arasında olmuştur. İnsanlık son derece etkili olabilen afetlerle veya felaketlerle başa çıkmak için geçmişten beri çalışmaktadır. Deprem de insanlığa en çok zarar veren, en yıkıcı olabilen afet türlerinden biridir. Bu sebeple depremler özellikle kentsel alanlarda her yıl binlerce can kaybına neden olmaktadır. Geçmiş depremlerde ki can kayıplarının sebepleri incelendiğinde, en çok can kaybının enkaz altında uzun süre kalan afetzedelerde yaşandığı görülmektedir. Afet yönetiminde deprem öncesi yapılan çalışmalar kadar deprem sonrasında ki yapılan çalışmalarda afetzedelere en kısa sürede ulaşmak ve maksimum sayıda afetzedenin hayatını kurtarmak için önemlidir. Afetzedelere en kısa sürede ulaşabilmek için afet bölgesindeki hasar görmüş veya yıkılmış olan binaları tespit etmek ve bu tespitler doğrultusunda kurtarma çalışmalarına yön vermek gerekmektedir. Gerçek zamanlı hasar tespit çalışmaları, afet yönetiminin kriz aşamasındaki müdahale sürecini etkin bir şekilde kolaylaştırabilecek ve hızlandırabilecektir. Bu sayede, afet bölgesinde bulunan kurtarma ekipleri enkaz altındaki afetzedelerin yerlerini kolayca tespit edebilecek ve zamanla yarışan afetzedeleri en kısa sürede kurtarabileceklerdir. Bu nedenle, kurtarma çalışmalarını kolaylaştırmak için ve can kaybını en aza indirmek için hasarlı binaların tespitlerini olabildiğince hızlı gerçekleştirmek gerekir.

#### **4.2. Araştırmanın Amacı**

Çalışmanın amacı; afet bölgesinde hasar görmüş binaları en kısa sürede tespit etmek, tespit edilen binaları hasar düzeylerine göre sınıflandırmak için bir model oluşturmaktır. Bu model sayesinde, kurtarma ekiplerine gerçek zamanlı ve doğruluğu

yüksek bilgiler vererek maksimum sayıda afetzedeyi kurtarmak ve minimum can kaybına ulaşmak hedeflenmektedir.

### **4.3. Araştırmanın Önemi**

Günümüzde, afetler gerçekleştikten sonra, afet bölgesindeki enkazları görebilmek, afetin sebep olduğu zararların boyutunu anlayabilmek, hasar alan binaları tespit edebilmek ve afet bölgesini yakından takip edebilmek için gerek uydularla ve helikopterle alınan hava görüntülerinden gerekse bölgede bulunan ekiplerin gözlemlerinden faydalanılmaktadır. Uydu görüntülerinin olumsuz hava şartlarındaki kullanımı zorlaşmakta ve uydu görüntülerinin boyutları büyük olduğundan dolayı işlenmesi güç olabilmekte, işleme hızı bakımından da olumsuzluklar yaşanabilmektedir. Afet bölgesinde bulunan ekipler, afetin sebep olduğu kargaşadan dolayı dikkat kaybı yaşayabilirler. Bu sebeple, kurtarma ekiplerinin önemli detaylara dikkat edemeyip gözden kaçırma ihtimalleri vardır. Bu çalışmada oluşturulan model, afet bölgesine gönderilecek olan “drone” gibi insansız hava araçlarından alınan görüntüleri kullanarak en kısa sürede hasarlı binaların tespiti gerçekleştirecektir. Bu sayede;

- i. Uydulardan alınan görüntüler gibi büyük boyutlara sahip verilerle çalışarak zaman kaybı yaşanmayacak,
- ii. Bulutlu, sisli gibi olumsuz hava şartlarında da kullanılabilir,
- iii. Afet bölgesine gözlem için personel gönderilmeye gerek kalmayacak,
- iv. Havadan görüntü almak için helikopterlerle görüntü almak gibi yüksek maliyet gerektiren etkinliklere gerek kalmayıp mali açıdan avantaj sağlanacak,
- v. “Drone” gibi insansız hava araçlarından gelen görüntüler gerçek zamanlı işlenebilir olacağından zamandan avantaj sağlanacak,
- vi. Verilerin hızlı işlenebilmesindeki avantajlar sayesinde afetlerin müdahale aşamasında ki arama ve kurtarma işlemleri daha da hızlanacaktır.

### **4.4. Araştırmanın Kapsamı**

Yapay zeka alanında makine öğrenmesinin alt dalına ait derin öğrenme algoritması olan evrişimli sinir ağları algoritmaları ve görüntü segmentasyon tekniği kullanılarak girdi olarak verilen bina görüntülerini hasarlı, daha az hasarlı ve normal




olmak üzere sınıflandırabilen model oluşturulması çalışmanın kapsamı olarak amaçlanmıştır.

#### 4.5. Araştırmanın Kısıtlıkları

Çalışmada veri olarak kullanılan bina görüntüleri image.google.com ve image.baidu.com gibi açık kaynaklardan toplanmıştır. Görüntülerin toplama aşamasında yüksek çözünürlükte ve gerçekçi görüntüler bulmak zorlanılmıştır. Özellikle çalışmanın ikinci aşamasında uygulanan çoklu sınıflandırma uygulamasında “daha az hasarlı” sınıfında kullanılması için gerekli bina görüntü sayıları çoğaltılmakta zorlukların yaşanması çalışmanın kısıtlıkları arasındadır.

#### 4.6. Araştırma Modeli

Şekil 18. Araştırma Modeli



Araştırma öncelikle çalışma için gerekli verileri toplayarak başlamakta, sonrasında toplanan verileri evrişimli sinir ağları ile algoritmalarla dönüştürülmektedir.

Dönüşen verilerin analizleri gerçekleştirildikten sonra verilerin ayrılacağı sınıflar oluşturulur. Veriler analizlerine göre sınıflara dağıtılır ve modelimiz tamamlanmış olur.

#### **4.7. Veri Toplama Araçları ve Yöntem**


Çalışmada veri olarak kullanılmak üzere 900 adet bina görüntüleri images.google.com ve images.baidu.com gibi açık kaynaklardan toplanmıştır. Toplanan verilerin %70’lik kısmı önceden eğitilmiş olan evrişimli sinir ağı modellerinin çalışmanın eğitimi için kullanılırken, diğer verilerin %15’lik kısmı doğrulama için, %15’lik kısmı ise önceden eğitilmiş olan modelin testinde kullanılmıştır. Ayrıca çalışmada kullanılan modellerin epoch (eğitim turu) sayılarını 300, öğrenme oranı ise 0.0001 olarak sabitlenmiştir.

Çalışmanın ilk aşamasında, 300 adet normal bina ve 300 adet hasarlı bina olmak üzere toplamda 600 adet bina görüntüleri kullanarak görüntüleri “normal” ve “hasarlı” olmak üzere ikili sınıflandırma yapabilen model oluşturmak amaçlanmıştır. Bu aşamada evrişimli sinir ağı mimarileri olan önceden eğitilmiş VGG-16, VGG-19 ve NASNet mimarileri kullanılmıştır.

Çalışmanın ikinci aşamasında, çoklu sınıflandırma gerçekleştirmek için 600 adet bina görüntülerine 300 adet daha az hasarlı bina görüntüleri eklenmiştir. Bu aşamada, görüntüleri “normal”, “hasarlı” ve “daha az hasarlı” olarak sınıflandırabilen model oluşturulmak amaçlanmıştır. Bu aşamada da evrişimli sinir ağı mimarileri olan önceden eğitilmiş VGG-16, VGG-19 ve NASNet mimarileri kullanılmıştır.

Tüm görüntüler, her iki aşamada da öncelikle K-means algoritması ve görüntü segmentasyon tekniği uygulanıldı. Böylece görüntüler, kümelenecek siyah beyaz renklere dönüştürüldü. Bunun sebebi hasarlı binaların görüntülerinde ki siyah bölgeler, normal binaların görüntülerinde ki siyah bölgelere oranla daha fazla olacaktır. Bu sayede modeller verileri daha iyi analiz yapabilecek, modellerin doğruluk oranı artacaktır.

**Şekil 19. Normal ve Hasarlı Binaların Orijinal ve Segmentasyonu Yapılmış Görüntüleri**



Çalışmanın ilk aşamasında uygulanan ikili sınıflandırmada modeller, değerlendirme metrikleri arasında yaygın olarak kullanılan doğruluk, duyarlılık, özgüllük ve G-ortalama puanı ölçütleri bakımından karşılaştırılmıştır. İki aşamada ki çoklu sınıflandırma da ise modeller değerlendirme metrikleri arasından doğruluk oranıyla karşılaştırılmıştır.

- Doğruluk oranı; incelenen toplam veri sayısı arasında gerçek sonuçların oranıdır, değerlendirme metriklerinin özüdür. Hem ikili hem de çoklu sınıflandırmalar için kolayca uygulanır.
- Duyarlılık oranı; “hasarlı” olarak sınıflandırılan hasarlı bina görüntülerinin yüzdesi gibi, doğru şekilde atanan pozitif örneklerin oranıdır.
- Özgüllük oranı; “normal” olarak sınıflandırılan normal bina görüntülerinin yüzdesi gibi, doğru şekilde atanan negatif örneklerin oranıdır.
- G-ortalama puanı; duyarlılık ve özgüllük oranlarının geometrik ortalamasıdır. Modelin hem duyarlılık hem de özgüllük oranlarında nasıl performans sergilediği hakkında daha iyi bilgi verir.

#### **4.8. Bulgular ve Yorumlar**

Çalışma ikili sınıflandırma ve çoklu sınıflandırma olmak üzere iki aşamadan oluştuğu için bu bölümde çalışmanın bulguları ve yorumları detaylı olarak ayrı ayrı incelenecektir.


Bu çalışmanın ilk aşaması için, “hasarlı” ve “normal” etiketli bölümlenmiş görüntüler sınıflandırıldı. VGG-19 modeli test setinde %90 doğrulukla en başarılı model olurken VGG16- modeli %88.8 doğrulukla NASNet modeli ise %78.8 doğrulukla başarılı olarak sonuçlanmıştır.

Çalışmanın ikinci aşamasında “hasarlı”, “normal” ve “daha az hasarlı” etiketli bölümlenmiş görüntüler sınıflandırıldı. VGG-19, VGG-16 ve NASNet modelleri sırasıyla yaklaşık %69, %66 ve %62.5 doğrulukla test setinde önemli başarılar elde etmişlerdir.

##### **4.8.1. İkili Sınıflandırma Bulguları ve Yorumları**


Çalışmanın ilk aşamasında “normal” ve “hasarlı” sınıflar oluşturularak ikili sınıflandırma uygulanmıştır. Bu aşamada 300 adet normal bina görüntüleri, 300 adet hasarlı bina görüntüleri kullanılmıştır. Çalışmanın bu aşamasında kullanılan modellerin epoch (eğitim turu) sayısı artıkça eğitim ve doğrulamada ki kayıplar, yanlışlıklar azalmaktadır.

**Şekil 20. VGG-16, VGG-19 ve NASNet Modellerinin Epoch (Eğitim Turu) Sayısına Göre Eğitim ve Doğrulama Kayıplarının Değerleri**



Üç model arasında VGG-19 modeli, en düşük kayıp değerini vermektedir. Bu sebeple, diğer iki modelden daha iyi performans sergilemektedir.


**Şekil 21. Eğitim ve Doğrulama Setlerinde VGG-16, VGG-19 ve NASNet'in Doğruluk Oranı**



Değerlendirme metrikleri arasından hem eğitim hem de doğrulama setinde VGG-19 modeli diğer modellere göre daha başarılı sonuçlar vermiştir.

Eğitim ve doğrulama setindeki kayıp değerleri, modelin olması gerektiği gibi eğitildiğini gösterse de modelin gerçek hayatta etkili kullanımı, modelin test setinde gösterdiği performanslara göre bulunabilir.

**Tablo 12. İkili Sınıflandırma Aşamasında VGG-16, VGG-19 ve NASNet Modellerin Test Setleri İçin Matrisleri**



Matrislerin sonuçlarını incelediğimizde VGG-16 modeli 46 normal bina görüntüsünden 42'sini doğru tespit ederken 44 hasarlı bina görüntüsünün 38 ini doğru tespit etmiştir. VGG-19 modeli 46 normal bina görüntüsünden 41'ini doğru tespit ederken 44 hasarlı binanın 40'ını doğru tespit etmiştir. NASNet modeli ise 46 normal binanın 45'ini doğru tespit ederken 44 hasarlı binanın 26'sını doğru tespit etmiştir.

**Tablo 13. VGG-16, VGG-19 ve NASNet'in Duyarlılık, Özgüllük ve G-Ortalama Skorları**

Evaluation Metrics	Formulation	VGG-16	VGG-19	NASNet
Loss in the test set		0.264	<b>0.234</b>	0.470
Accuracy in the test set		0.888	<b>0.900</b>	0.788
Sensitivity	$\frac{TP}{TP + FN}$	0.913	0.891	<b>0.978</b>
Specificity	$\frac{TN}{TN + FP}$	0.863	<b>0.909</b>	0.590
G-Mean	$\sqrt{Sensitivity \times Specificity}$	0.887	<b>0.900</b>	0.759


Tablo 13. görüldüğü üzere modellerin G-ortalama puanlarına bakıldığında VGG-19 modeli diğer modellere göre daha başarılı olmuştur.

Sonuç olarak, hasarlı ve normal binaların sınıflandırılması açısından, VGG-19 modeli, diğer modellere kıyasla test setinde %90 doğruluk oranı ile daha başarılı bir sonuç vermiştir.

#### 4.8.2. Çoklu Sınıflandırmanın Bulguları ve Yorumları


Çalışmanın ikinci aşamasında “normal” ve “hasarlı” sınıflarına ek olarak “daha az hasarlı” sınıfı da oluşturularak çoklu sınıflandırma uygulanmıştır. “Daha az hasarlı” sınıfını oluşturmak için önceki aşamada kullanılan görüntülere ek olarak 300 adet daha az hasarlı bina görüntüleri eklenmiştir.

**Şekil 22. Çoklu Sınıflandırma İçin Epoch (Eğitim Turu) Sayısına Göre VGG-16, VGG-19 ve NASNet'in Eğitim ve Doğrulama Kayıplarının Değerleri**




Her üç modelin de olması gerektiği gibi epoch (eğitim turu) sayısına paralel olarak kayıp değerlerinin düştüğü görülmektedir. Ayrıca NASNet modeli, diğer modellere göre daha başarısız olduğu görülmektedir.

**Şekil 23. Çoklu Sınıflandırma İçin Eğitim ve Doğrulama Setlerinde VGG-16, VGG-19 ve NASNet'in Doğruluk Oranları**



VGG-16 ve VGG-19 modelleri hem eğitim hem de doğrulama setinde benzer özellikler göstermiştir. Kayıp değeri açısından VGG-16 modeli, eğitim ve doğrulama setinde biraz daha başarılı sonuçlanmıştır. Şekil 23. görüldüğü gibi VGG-16 doğrulama kümesinde ki doğruluk açısından VGG-19 modeline göre biraz daha başarılı olmuştur. Ancak, VGG-16 modelinin grafik çizimi VGG-19 modeline göre daha fazla dalgalandığı görülmektedir. Diğer yandan, NASNet diğer iki modele kıyasla doğruluk ve kayıp açısından oldukça başarısız olmuştur.

**Tablo 14. Çoklu Sınıflandırma Aşamasında VGG-16, VGG-19 ve Nasnet Modellerin Test Setleri İçin Matrisleri**



Çoklu sınıflandırmada üç modelin test setleri için olan matrisleri incelendiğinde en dikkat çekici nokta, her üç modelin normal bina ve hasarlı binaları doğru şekilde sınıflandırırken daha az hasarlı binaları sınıflandırma da daha az başarı oranı



göstermesidir. VGG-16 ve VGG-19 modelleri daha az hasarlı binaların çoğunu hasarlı bina olarak kabul ederek yanlış sınıflandırmıştır. NASNet modeli ise daha az hasarlı binaların çoğunu normal bina olarak kabul etmiş ve yanlış sınıflandırmıştır.

**Tablo 15. VGG-16, VGG-19 ve NASNet'in Çoklu Sınıflandırmada Duyarlılık, Özgüllük ve G-Ortalama Skorları**

<b>Evaluation Metrics</b>	<b>VGG-16</b>	<b>VGG-19</b>	<b>NASNet</b>
Loss in the test set	0.672	<b>0.640</b>	0.791
Accuracy in the test set	0.669	<b>0.691</b>	0.625

Üç modelin çoklu sınıflandırmada ki test setinde gösterilen performansları incelendiğinde, VGG-19 modeli modeller arasında en iyi doğruluk ve kayıp oranlarını vermiştir.

#### **4.10. Tartışma**

2015 yılında, J. Fernandez Galarreta ve arkadaşları eğik, çok perspektifli ve çok yüksek çözünürlüklü görüntülere dayalı binalara hasar puanlaması yapmak üzere çalışma gerçekleştirmişlerdir. Bina görüntülerini İHA ve direğe monte edilmiş kameralardan elde etmişlerdir. Görüntüler öncelikle 3D bulut sistemine aktarılmış, sonrasında binaların hasar özelliklerini çıkarmak için OBIA modeli ile analiz edilmiştir. Ayrıca görüntülerin kolayca karakterize edilebilmesi için görüntü segmentasyonu tekniğinden faydalanılmıştır. Çalışmada 6 farklı sınıf oluşturarak çoklu sınıflandırma uygulanmıştır. Çalışmada modelin verileri doğru sınıflara ayrılma orayı yüzde 40 ile 80 oranları arasında değişiklik göstermiştir. Bu çalışmada binaların iki boyutlu görüntüleri kullanılmıştır. Çalışmada ikili sınıflandırma ve çoklu sınıflandırma uygulanarak iki aşamadan oluşturulmuştur. İkili sınıflandırma aşamasında %90 doğruluk oranına ulaşılmış, çoklu sınıflandırmada 3 farklı sınıf oluşturuldu ve bu aşamada modeller ortalama %66 doğruluk prarıyla sonuçlanmıştır.

Anand Vetrivel ve arkadaşları, 2016 yılında binaların afet öncesi ve sonrasındaki 3 boyutlu görüntülerini karşılaştırarak afet sonrasında binalarda hasar tespitinde bulunma amaçlı çalışma gerçekleştirmişlerdir. Çalışmada ilk olarak binaların afet öncesi

görüntülerini analiz etmek için binaların görüntüleri 3 boyutlu görüntülere dönüştürülmüş, sonrasında binaların hasarlarını tespit etmek için afet sonrası görüntüler ile karşılaştırılmış ve hasar oranlarını belirlemek için sınıflandırma işlemi gerçekleştirilmiştir. Çalışmada kullanılan model, verilerin %87'sini doğru tespit ederek başarılı sonuçlanmıştır. Bu çalışmada binaların iki boyutlu olan afet sonrası görüntüleri kullanılmıştır. Modeller ikili sınıflandırmada yaklaşık %90, çoklu sınıflandırmada yaklaşık %68 doğruluk oranıyla sonuçlanmıştır.

Aito Fujita ve arkadaşları, 2017 yılında tsunami sonrası yıkanmış bölgeleri tespit etmek için evrişimli sinir ağı modeli kullanmışlardır. Çalışmalarında girdi verileri için tsunami öncesinde havadan çekilmiş görüntüler kullanmışlardır, 6 katmanlı evrişimli sinir ağı konfigürasyonunu kullanmışlardır. Giriş ölçeği olarak sabit ölçekli, yeniden boyutlandırılmış, merkezi çevrelerini dikkate alan kapsamlı çalışma gerçekleştirmişlerdir. Çalışmalarında kullandıkları model %94-96 doğruluk göstererek sonuçlanmıştır. Bu çalışmada yıkanmış binalar yerine hasar görmüş binaların görüntüleri kullanılarak binalarda hasar oranı tespit edilmeye çalışılmıştır. Bu çalışmada evrişimli sinir ağı mimarileri arasından 13 ve 16 katmanlı modeller kullanılmış olup, modeller %90 doğruluk oranıyla sonuçlanmıştır.

D. Duarte ve arkadaşları 2017 yılında bir dizi insansız hava aracı (İHA) çoklu görünüm görüntüsü kullanılarak cephe hasar tespitinin verimliliğini artırmak için çalışma gerçekleştirmişlerdir. Çalışmada 4 ana cephe yönü, İHA'nın navigasyon sisteminden gelen ham yönlendirme bilgileri ile birlikte, eğik görüntülerdeki cepheleri tanımlamak için kullanılmıştır. Bu çalışmada binaların tek bir cephesinden alınmış görüntüleri kullanılması düşünülmüştür.

Anand Vetrivel ve arkadaşları, 2018 yılında evrişimli sinir ağlarını, 3D nokta bulut özelliklerini kullanarak hasar sınıflandırması yapabilen denetimli öğrenme modeli oluşturmuşlardır. Çalışmada üç farklı senaryo üzerinde hasar tespit çalışmaları gerçekleştirmişlerdir. İlk senaryoda modeli sıfırdan eğiterek hasar tespiti gerçekleştirmişlerdir, ikinci senaryoda önceden eğitilmiş modelin etki alanına dayanan hasar tespiti gerçekleştirmişlerdir, son olarak üçüncü senaryoda görüntülere dayanan önceden eğitilmiş model kullanarak hasar tespit çalışmaları gerçekleştirmişlerdir. Bu senaryolarda çoğu zaman yaklaşık %85'lik doğruluk oranıyla sonuçlandığı görülmüştür.

Bu alıřmada iki ařamada da tek tip senaryo dūřūnūlerek denetimli ۆğrenme modeli kullanılmıřtır.

Diogo Duarte ve arkadaşları 2018 yılında, evriřimli sinir ağıları ile hasarlı binaların görüntülerini sınıflandırmak için alıřma gerekleřtirmiřlerdir. alıřmada üç farklı evriřimli sinir ağı özelliğı kullanılmıřtır. Ayrıca, kullanılan bina görüntüleri havadan görüntüleme tekniğinden ve uydu görüntülerinden elde edilmiřtir. alıřmada kullanılan modeller test setlerinde doğruluk oranları %80-92 aralığında sonuçlar göstermiřlerdir. Bu alıřmada da üç farklı evriřimli sinir ağı mimarisi kullanılmıřtır. Modeller %90'lık doğruluk oranını yakalayabilmiřlerdir.

## SONUÇ VE DEĞERLENDİRME

Doğal afet türü olan depremler, en yıkıcı afet türlerinden biridir, özellikle kentsel alanlarda meydana geldiğinde çok sayıda can ve mal kaybına sebep olmaktadır. Depremler nedeniyle yaşanan can kayıplarının büyük çoğunluğu enkaz altında uzun süre kalmaktan kaynaklandığı görülmektedir. Bu sebeple deprem gerçekleştiğinde, depremin sebep olduğu enkazları, enkaz bölgelerini, hasar görmüş binaları ve bu binaların hasar seviyelerini en kısa sürede tespit etmek gerekmektedir. Edilen tespitler doğrultusunda da afet yönetiminin müdahale aşamasını şekillendirmek gereklidir. Günümüzde yaşanan depremlerde hasar tespit çalışmaları için genellikle uydulardan ve afet bölgesine gönderilen helikopter gibi hava araçlarından alınan görüntüler veya bölgede bulunan personellerden alınan gözlemler gibi yöntemler kullanılmaktadır. Fakat bu yöntemlerin ekonomik, zaman ve dikkat dağınıklığı gibi bazı dezavantajları bulunmaktadır. Dezavantajları ortadan kaldırmak için ekonomik ve kolay uygulanabilir yöntemler geliştirilmelidir.

Günümüzde birçok deprem algılayıcı veya uyarıcı sistemler bulunmasına rağmen depremlerin ölümcül etkilerini azaltmak hala zordur. Bu nedenle, deprem gerçekleştikten sonra depremin gerçekleştiği bölgede kullanılabilecek hızlı sonuçlanabilen tespit sistemleri geliştirilmelidir. Bu çalışmada, yapay zekanın sağlamış olduğu avantajlardan faydalanarak deprem gerçekleştikten sonra deprem bölgesinde bulunan binaların en kısa sürede hasarlarını tespit edebilen ve hasar oranına göre binaları 3 farklı sınıfa ayırabilen bir modelin oluşturulması amaçlanmıştır. Modelde veri olarak kullanılacak olan bina görüntüleri 300 adet normal bina, 300 adet hasarlı bina ve 300 adet daha az hasarlı bina olmak üzere 900 adet bina görüntüsü toplanmıştır. Bu görüntüler [images.google.com](https://images.google.com) ve [images.baidu.com](https://images.baidu.com) gibi açık kaynaklı sitelerden elde edilmiştir. Modelin işlenmesinde önceden eğitilmiş evrişimli sinir ağları kullanılmıştır. Bina görüntülerinin daha kolay analizlenmesi için görüntü segmentasyonu tekniği kullanılmıştır. Görüntü segmentasyonu uygulanan görüntülere, birbirlerinden daha kolay ayırt edilebilmesi için K-means algoritması uygulanmıştır. Tüm uygulamalardan sonra görüntüler VGG-16, VGG-19 ve NASNet olmak üzere önceden eğitilmiş 3 farklı evrişimli sinir ağı

mimarilerine girdi olarak verilmiş ve modelin işlenebilirliği test edilmiştir. Bu mimarilerin sonuçları, değerlendirme metrikleri arasında yaygın olarak kullanılan doğruluk, duyarlılık, özgüllük ve G-ortalama puanı ölçütleri bakımından karşılaştırılmıştır.

Çalışma iki aşamadan oluşmaktadır. İlk aşamada, modele verilen görüntülerin “normal” ve “hasarlı” olarak adlandırılan iki farklı sınıfa ayrılması amaçlanmıştır. Bu sebeple modelden ikili sınıflandırma yapılması istenmiştir. Bu aşamanın sonunda VGG-16 modeli %88.8, VGG-19 modeli %90, NASNet modeli ise %78.8 doğruluk oranıyla sonuçlanmıştır. VGG-16 ve VGG-19 modelleri benzer sonuçlar gösterse de VGG-19 en başarılı model olmuştur. NASNet modeli diğer iki modele göre daha az başarılı olmuştur.

Çalışmanın ikinci aşamasında modelden görüntüleri “normal”, “hasarlı” ve “daha az hasarlı” olmak üzere üç sınıfa ayırması için modelden çoklu sınıflandırma yapması istenmiştir. Bu aşamanın sonunda VGG-16 modeli %66, VGG-19 modeli %69, NASNet modeli ise %62.5’lik doğruluk oranı sergilemiştir. İlk aşamada olduğu gibi ikinci aşamada da VGG-19 modeli en başarılı model olmuştur.

Modelin problemlerine baktığımızda ikinci aşamada istenen çoklu sınıflandırmada modellerin ikili sınıflandırmaya göre nispeten başarısız olduğu görülmüştür. Bunun sebebi, modeller daha az hasarlı olarak kullanılan verileri normal ve hasarlı binalarla karıştırarak doğru sınıflara ayıramamıştır. Çalışmanın devamında modelde kullanılan görüntülerin sayıları, özellikle daha az hasarlı olan görüntülerin sayıları, arttırılarak modellerin daha başarılı sonuçlar elde edeceği düşünülmektedir.

Birçok alanda yapay zekanın insanlığa sağlamış olduğu avantajlardan yararlanıldığı gibi afet yönetiminin bütün dönemlerinde de yapay zekanın avantajlarından faydalanılmalıdır. Afet yönetiminde yapay zekanın kullanımı geliştirilerek genişletilmelidir.

## KAYNAKÇA

- AFAD (2020), 30 Ekim 2020 Sisam adası (İzmir Seferihisar açıkları) mw 6.6 depremi raporu
- Aktel, M., & Çağlar, N. (2007). Isparta ili afet (kriz) yönetim yapılanması üzerine bir çalışma. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 12(3), 147-162.
- Alpaydin, E. (2020). Introduction to machine learning. Mıt Press.
- Altun, F. (2018). Afetlerin ekonomik ve sosyal etkileri: Türkiye örneği üzerinden bir değerlendirme. Turkish Journal Of Social Work, 1–15.
- Arca, D. (2012). Afet yönetiminde coğrafi bilgi sistemi ve uzaktan algılama. Karaelmas Fen ve Mühendislik Dergisi, 2(2), 53–61.
- Arel, I., Rose, D., & Karnowski, T. (2010). Deep machine learning-a new frontier in artificial intelligence research. Ieee Computational Intelligence Magazine, 5(4), 13–18.
- Aydın, F., & Aslan, Z. (2017). Yapay öğrenme yöntemleri ve dalgacık dönüşümü kullanılarak nöro dejeneratif hastalıkların teşhisi. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 32(3).
- Aydiner, T. (2014). Doğal afet yönetişimi: Türkiye'de doğal afet yönetimi uygulamalarının tarihsel bağlamda değerlendirilmesi (Master's Thesis).
- Aydoğan, M., & Abdullah Şener. (2020). An artificial intelligence application in health developed on Covid-19 documents. Journal Of Health, Medicine And Nursing, June.
- Baykan, N. A., & Sağlam, A. (2018). Fast k-means color image clustering with normalized distance values. Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi, 6(2), 175-187.

- Bedük, Mehmet Seçkin (2011) Bulanık C-ortalama algoritması ile renkli görüntü segmentasyonu (Master's Thesis).
- Beşer, F., Kizrak, M. A., Bolat, B., & Yildirim, T. (2018, May). Recognition of sign language using capsule networks. In 2018 26th Signal Processing And Communications Applications Conference (SIU) (Pp. 1-4). IEEE.
- Bitelli, G., Camassi, R., Gusella, L., & Mognol, A. (2004). Image change detection on urban area: the earthquake case. In Xxth Isprs Congress, Istanbul, Turkey, 35, 692–697.
- Bormann, P. (2020). Earthquake, magnitude. Encyclopedia Of Solid Earth Geophysics, 1–12.
- Büyükbaş, E., & Ormanoğlu, B. (Y.Y.). Afetler ve afet yönetiminde meteorolojinin yeri. Türkiye İdare Dergisi, 476.
- Corbane, C., Carrion, D., Lemoine, G., & Broglia, M. (2011). Comparison of damage assessment maps derived from very high spatial resolution satellite and aerial imagery produced for the Haiti 2010 earthquake. Earthquake Spectra, 27(S1), S199-S218.
- Çağlar, N., Kırtel, O., Vural, İ., Sümer, Y., & Sarıbiyık, A. (2020). 24 Ocak 2020 Mw 6.8 Elazığ-Sivrice depremi inceleme ve değerlendirme raporu. Sakarya University, 1–38.
- Carbonell, J. G., Michalski, R. S., & Mitchell, T. M. (1983). An overview of machine learning. In Machine Learning (Pp. 3-23). Morgan Kaufmann.
- Çatal, H. H. (2019). Deprem sonrası düzenlenen hasar tespit formlarının kıyaslanması.
- Cheng, H. D., Jiang, X. H., Sun, Y., & Wang, J. (2001). Color image segmentation: advances and prospects. Pattern Recognition, 34(12), 2259–2281.
- Çoban, H. (2019). Afet sonrası iyileştirme planı hazırlanması. Resilience, 3(2), 239–246
- İşçi, C. (2008). Deprem nedir ve nasıl korunuruz?. Journal Of Yasar University, 3(9), 959-983.

- Delamater, N. (2018). A brief history of artificial intelligence and how it's revolutionizing customer service today. Smartmax Software, Inc, 1–9.
- Deng, L., & Yu, D. (2013). Deep learning: methods and applications. *Foundations And Trends In Signal Processing*, 7(3–4), 197–387.
- Dey, A. (2016). Machine learning algorithms: A review. *International Journal Of Computer Science And Information Technologies*, 7(3), 1174–1179.
- Devlet Planlama Teşkilatı (1999), 1999 yılı programının uygulanması, Koordinasyonu ve İzlenmesine Dair Karar
- Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal Of Computer And Information Sciences*, 1(April), 10–21.
- Dong, L., & Shan, J. (2013). A comprehensive review of earthquake-induced building damage detection with remote sensing techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 84, 85-99.
- Duarte, D., Nex, F., Kerle, N., & Vosselman, G. (2017). Towards a more efficient detection of earthquake induced facade damages using oblique wav imagery. *The International Archives Of Photogrammetry, Remote Sensing And Spatial Information Sciences*, 42, 93.
- Duarte, D., Nex, F., Kerle, N., & Vosselman, G. (2018). Multi-resolution feature fusion for image classification of building damages with convolutional neural networks. *Remote Sensing*, 10(10), 1636.
- Elnashai, A. S., & Di Sarno, L. (2015). *Fundamentals of earthquake engineering: from source to fragility*. John Wiley & Sons.
- Erkal, T., & Değerliyurt, M. (2009). Disaster management of Turkey. *Doğu Coğrafya Dergisi*, 14(22), 147–164.



- Ergünay, O. (1996). Türkiye’de afet zararlarının azaltılması konusunda yapılan ve yapılması gereken çalışmalar hakkında rapor. Afet İşleri Genel Müdürlüğü, Ankara.
- Evrin, I. (2017). Yapay zeka ’ nın teorik ve pratik sınırları zeki sistemler artık her yerde.
- Eygü, H., & Karabacak, E. (2017). Afet lojistik yönetimi temelinde risk yönetim endeksi verileriyle Türkiye ile AB üye ülkelerinin karşılaştırması. İktisadi ve İdari Bilimler Dergisi, 627.
- Fernandez Galarreta, J., Kerle, N., & Gerke, M. (2015). UAV-Based urban structural damage assessment using object-based image analysis and semantic reasoning. Natural Hazards & Earth System Sciences, 15(6).
- Ferreira, M. D., Corrêa, D. C., Nonato, L. G., & De Mello, R. F. (2018). Designing architectures of convolutional neural networks to solve practical problems. Expert Systems With Applications, 94, 205–217.
- Fujita, A., Sakurada, K., Imaizumi, T., Ito, R., Hikosaka, S., & Nakamura, R. (2017, May). Damage detection from aerial images via convolutional neural networks. In 2017 Fifteenth IAPR International Conference On Machine Vision Applications (MVA) (Pp. 5-8). IEEE.
- Gazete, R. (2009). Afet ve acil durum yönetimi bakanlığının teşkilat ve görevleri hakkında kanun. Resmi Gazete, 5902.
- Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. Nature, 521(7553), 452–459.
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. California Management Review, 61(4), 5–14.
- Haralick, R. M., & Shapiro, L. G. (1985). Image segmentation techniques. Computer Vision, Graphics, & Image Processing, 29(1), 100–132.

Hoyois, P., Below, R., Scheuren, J. M., & Guha-Sapir, D. (2007). Annual disaster statistical review 2006: numbers and trends. Centre For Research On The Epidemiology Of Disasters (Cred).

<https://www.afad.gov.tr/> Eriřim Tarihi: 10.11.2020

<https://www.afad.gov.tr/afet-turleri> Eriřim Tarihi: 06.09.2020

<https://www.afad.gov.tr/aydes-uzaktan-algilama-uzal55> Eriřim Tarihi: 12.12.2020

<https://www.emdat.be/classification> Eriřim Tarihi: 10.09.2020

<https://deprem.afad.gov.tr/deprem-tehlike-haritasi> Eriřim Tarihi: 9.11.2020

<https://www.emdat.be/classification> Eriřim Tarihi: 10.09.2020

[http://www.koeri.boun.edu.tr/depremmuh/deprem-raporlari/Van\\_Eq\\_ED-15112011-2.pdf](http://www.koeri.boun.edu.tr/depremmuh/deprem-raporlari/Van_Eq_ED-15112011-2.pdf) Eriřim Tarihi: 12.12.2020

<https://www.nkfu.com/deprem-nedir-ve-depremlerden-korunma>

Eriřim Tarihi: 12.11.2020

<https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem-cesitleri-nelerdir/>  
Eriřim Tarihi: 10.11.2020

[\\_https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem-cesitleri-nelerdir/](https://parlakayse.wordpress.com/deprem-nedir-nasil-olusur-deprem-cesitleri-nelerdir/)  
Eriřim Tarihi: 10.11.2020

Hu, Y. X., Liu, S. C., & Dong, W. (1996). Earthquake engineering. Crc Press.

İlhan, A. M. (2013). Afetler ve insani yardım operasyonlarında silahlı kuvvetlerin rolü. Güvenlik Bilimleri Dergisi, 2(1), 107–129.

Iřın, G. (2004). Deprem: suçlu kim. Pivolka, 3(13), 7–12.

İskender, H., & Erdoğan, N. (2007). Afet durum iyileřtirme planlamasında gönüllü kaynakların yönetimi. TMMOB Afet Sempozyumu Bildiriler Kitabı, Ankara.

İřÇİ, Cořkun, (2008), Deprem Nedir ve Nasıl Korunuruz?, Journal of Yasar University, s.959-983.

- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *Acm Computing Surveys (Csur)*, 31(3), 264–323.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: trends, perspectives, and prospects. 349(6245).
- Kadıoğlu, M. (2008). Modern, bütünleşik afet yönetimin temel ilkeleri. *Afet Zararlarını Azaltmanın Temel İlkeleri*, 7(1).
- Kasap, R., & Gürten, Ü. (2003). Deprem magnitüdleri için tekrarlanma yıllarının elde edilmesi: Marmara Bölgesi örneği.
- Kayı, A., Erdoğan, M., & Yılmaz, A. (2015). Depremde hasar gören binaların uzaktan algılama yöntemleriye tespiti. *Tufuab VIII. Teknik Sempozyumu*, 2011, 226–230.
- Kok, J. N., Boers, E. J. W., Kusters, W. A., Putten, P. Van Der, & Poel, M. (2010). Artificial intelligence: definition, trends, techniques and cases. 1096–1097.
- Küçük, D., & Arıcı, N. (2018). Doğal dil işlemede derin öğrenme uygulamaları üzerine bir literatür çalışması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2(2), 76-86.
- Küçükkülahlı, E., Erdoğan, P., & Polat, K. (2016). Histogram-Based automatic segmentation of images. *Neural Computing And Applications*, 27(5), 1445–1450.
- Kurt, F. (2018). Evrişimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi. *Master's Thesis, Eğitim Bilimleri Enstitüsü*
- Landwehr, P. M., & Carley, K. M. (2014). Social media in disaster relief. In *Data Mining And Knowledge Discovery For Big Data* (Pp. 225-257). Springer, Berlin, Heidelberg.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Lecun, Y., Member, Ieee, Bottou, L., 'Eon, Bengio, Y., & Haffner, P. (1998). Gradient-Based learning applied to document recognition. *Proceedings Of The Ieee*, 86(11), 2278–2324.

- Mccorduck, P., Minsky, M., Selfridge, O., G., O., & Simon, H. A. (1977). History of artificial intelligence. In *Ijcaı*, 951–954.
- Mcloughlin, D. (1985). A framework for integrated emergency management. *Public Administration Review*, 45, 165–172.
- Mellit, A., Kalogirou, S. A., Hontoria, L., & Shaari, S. (2009). Artificial intelligence techniques for sizing photovoltaic systems : a review. 13, 406–419.
- Memiş, L., & Babaoğlu, C. (2020). Afet yönetimi ve teknoloji. Ankara: Nobel Yayıncılık, March, 163–178.
- Messer, N. M. (2003). The role of local institutions and their interaction in disaster risk mitigation: A literature review. Food And Agriculture Organization, United Nations, September.
- Muhammad, U., Wang, W., Chattha, S. P., & Ali, S. (2018). Pre-trained VGGNet architecture for remote-sensing image scene classification. *Proceedings - International Conference On Pattern Recognition*, 2018-Augus, 1622–1627.
- Onan, A., & Korukoğlu, S. (2016). Makine öğrenmesi yöntemlerinin görüş madenciliğinde kullanılması üzerine bir literatür araştırması. *Pamukkale University Journal Of Engineering Sciences*, 22(2).
- Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Özkul, B., & Karaman, A. E. (2007). Doğal afetler için risk yönetimi. *Tmmob Afet Sempozyumu Bildiriler Kitabı*, 251–260.
- Peemen, M., Shi, R., Lal, S., Juurlink, B., Mesman, B., & Corporaal, H. (2016, March). The neuro vector engine: flexibility to improve convolutional net efficiency for wearable vision. In *2016 Design, Automation & Test In Europe Conference & Exhibition (DATE)* (Pp. 1604-1609). IEEE.

- Petak, W. J. (1985). Emergency management : a challenge for public. *Public Administration Review* 45, 45, 3–7.
- Pi, Y., Nath, N. D., & Behzadan, A. H. (2020). Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. *Advanced Engineering Informatics*, 43(October 2019), 101009.
- Pirim, A. G. H. (2006). Yapay zeka. *Journal Of Yaşar University*, 1(1), 81-93.
- Press, F., & Hamilton, R. M. (1999). Mitigating natural disasters. *Science*, 284, 1927.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., & Lo, B. (2017). Deep learning for health informatics. 21(1), 4–21.
- Ray, P. P., Mukherjee, M., Shu, L. E. I., & Member, S. (2017). Internet of things for disaster management : state-of-the-art and prospects. *Ieee Access*, 5(5), 18818–18835.
- Reasürör Dergisi (2017), Türk afet yönetimine katkı yeni bir sistem, DASK afet risk yönetim sistemine bir bakış,
- Schweier, C., & Markus, M. (2006). Classification of collapsed buildings for fast damage and loss assessment. *Bulletin Of Earthquake Engineering*, 177–192.
- Şeker, A., Diri, B., & Hüseyin, H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme A review about deep learning methods and applications. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47–64.
- Shafiq, F., & Ahsan, K. (2013). Knowledge management for disaster scenario : An exploratory study. *Research Journal Of Recent Sciences*, 2(10), 61–66.
- Shailaja, K., Seetharamulu, B., & Jabbar, M. A. (2019). Machine learning in healthcare. *Proceedings Of The 2nd International Conference On Electronics, Communication And Aerospace Technology (Iceca 2018) Ieee Conference Record*, 25(2), 100–101.

- Sinha, A., Kumar, P., Rana, N. P., Islam, R., & Dwivedi, Y. K. (2019). Impact of internet of things ( iot ) in disaster management : a task-technology fit perspective. *Annals Of Operations Research*, 283(1), 759–794.
- Sümer, E., & Türker, M. (Y.Y.). Prem sonrası hava fotoğraflarından bina hasar tespiti için bütünleşik bir sistem yaklaşımı: Bidhas. 3.
- Sür, Ö. (1993). Türkiye'nin deprem bölgeleri. *Türkiye Coğrafyası Araştırma ve Uygulama Merkezi Dergisi*, 53–68.
- Tercan, B. (2019). Türkiye’de afet ve yeniden yerleştirme (iskân) politikaları: Doğubayazıt depremi örneği.
- Tuççe, U. Z. U. N. Yapay zeka ve sağlık uygulamaları. *İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(1), 80-92.
- Tzeng, W. C., Feng, H. P., Cheng, W. T., Lin, C. H., Chiang, L. C., Pai, L., & Lee, C. L. (2016). Readiness of hospital nurses for disaster responses in taiwan: a cross-sectional study. *Nurse Education Today*, 47, 37–42.
- Uğur, A., & Işık, M. (2020). Türkiye’nin afetlere hazırlık politikalarının toplum algısı üzerinden karşılaştırmalı analizi: Van-Bitlis illeri örneği. *Doğal Afetler ve Çevre Dergisi*, 90(434), 1–21.
- Uysal, M., Yılmaz, M., Tiryakioğlu, İ., & Polat, N. (2018). İnsansız hava araçlarının afet yönetiminde kullanımı. *Bilimler, Eskişehir Teknik Üniversitesi Bilim ve Teknoloji Dergisi B- Teorik*, 219–224.
- Varol, N., & Kaya, Ç. M. (2018). Afet risk yönetiminde transdisipliner yaklaşım. *Afet ve Risk Dergisi*, 1(1), 1–8.
- Vetrivel, A., Duarte, D., Nex, F., Gerke, M., Kerle, N., & Vosselman, G. (2016). Potential of multi-temporal oblique airborne imagery for structural damage assessment. *ISPRS Annals Of The Photogrammetry, Remote Sensing And Spatial Information Sciences*, 3, 355.

- 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.
- Weston, J., & Collobert, R. (2008). A unified architecture for natural language processing : deep neural networks with multitask learning. In *Proceedings Of The 25th International Conference On Machine Learning*, 160–167.
- Wu, X., Ghaboussi, J., & Garrett, J. H. (1992). Use of neural networks in detection of structural damage. *Computers And Structures*, 42(4), 649–659.
- Yağcı, C., Gökçe, İ., Bozüyük, T., & Akar, G. (2005). Yapay zeka teknolojilerinin endüstriyel uygulamaları. 67.
- Yampolskiy, R. V., & Spellchecker, M. S. (2016). Artificial intelligence safety and cybersecurity: a timeline of AI failures. *Arxiv Preprint Arxiv*, 1610.07997.
- Yanowitz, S. D., & Bruckstein, A. M. (2009). A new method for image segmentation. *Computer Vision, Graphics, And Image Processing*, 46, 82–95.
- Yılmaz, A. (2003). Afet yönetimi. Pegem A Yayıncılık, Ankara, Turkey.
- Yönetmeliği, B. K. Y. M. (1997). Başbakanlık kriz yönetim merkezi yönetmeliği. 25 Ocak, 2015 Tarihinde İndirildi.
- Yu, M., Yang, C., & Li, Y. (2018). Big data in natural disaster management: a review. *Geosciences*, 8(5), 165.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition*, 8697–8710.

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Adı Soyadı : Recep KİRİŞ  
Doğum Yeri ve Tarihi : Denizli 13.03.1994

### Eğitim Durumu

Lisans Öğrenimi : Gümüşhane Üniversitesi/ Acil Yardım ve Afet Yönetimi  
Yüksek Lisans Öğrenimi : Gümüşhane Üniversitesi/ Afet Yönetimi  
Bildiği Yabancı Diller : İngilizce

### İş Deneyimi

Çalıştığı Kurumlar : Öğrenci

### İletişim

E-posta : recepp.kiriss@gmail.com  
Tarih : 22.01.2021