

**T.C.**  
**GÜMÜŞHANE ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**DEPREM SONRASI HASARLI YOLLARIN YAPAY ZEKÂ İLE TESPİT  
EDİLEREK EN KISA YOL GÜZERGÂHLARININ ANLIK OPTİMİZASYONU**

**YÜKSEK LİSANS**

**Nurcan ŞİMŞEK**

**ŞUBAT-2022**  
**GÜMÜŞHANE**



**T.C.**

**GÜMÜŞHANE ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**DEPREM SONRASI HASARLI YOLLARIN YAPAY ZEKÂ İLE TESPİT  
EDİLEREK EN KISA YOL GÜZERGÂHLARININ ANLIK OPTİMİZASYONU**

**INSTANT OPTIMIZATION OF THE SHORTEST ROUTES BASED ON  
AUTOMATED DETECTION OF THE DAMAGED ROADS AFTER AN  
EARTHQUAKE WITH ARTIFICIAL INTELLIGENCE**

**YÜKSEK LİSANS**

**Nurcan ŞİMŞEK**

**ŞUBAT-2022  
GÜMÜŞHANE**



**T.C.**

**GÜMÜŞHANE ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**AFET YÖNETİMİ ANABİLİM DALI**

**DEPREM SONRASI HASARLI YOLLARIN YAPAY ZEKÂ İLE TESPİT  
EDİLEREK EN KISA YOL GÜZERGÂHLARININ ANLIK OPTİMİZASYONU**

**INSTANT OPTIMIZATION OF THE SHORTEST ROUTES BASED ON  
AUTOMATED DETECTION OF THE DAMAGED ROADS AFTER AN  
EARTHQUAKE WITH ARTIFICIAL INTELLIGENCE**

**YÜKSEK LİSANS**

**Nurcan ŞİMŞEK**

**Danışman: Doç. Dr. Ramazan ÜNLÜ**

**ŞUBAT-2022  
GÜMÜŞHANE**



## BİLİMSEL ETİĞE UYGUNLUK BEYANI

**Yüksek Lisans Tezi** olarak hazırlamış olduğum “**Deprem Sonrası Hasarlı Yolların Yapay Zekâ İle Tespit Edilerek En Kısa Yol Güzergâhlarının Anlık Optimizasyonu**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi'nin lisanslı kullanıcısı olduğum intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü'nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

**25/02/2022**

.....  
Nurcan ŞİMŞEK

## TEŞEKKÜR

Öncelikle bu tez çalışmasının gerçekleştirilmesinde en büyük emeği olan, tez çalışmamın planlanmasında, yürütülmesinde ve oluşumunda desteğini esirgemeyen bilgi ve tecrübelerinden yararlandığım sayın danışman hocam Doç. Dr. Ramazan ÜNLÜ'ye teşekkürü borç bilir ve saygılarımı sunarım.

Lisans ve yüksek lisans eğitimim boyunca katkıları olan sayın Prof. Dr. Saime ŞAHİNÖZ'e, sayın Doç. Dr. Afşin Ahmet KAYA'ya, sayın Dr. Öğr. Üyesi Sevil CENGİZ'e ve sayın Dr. Öğr. Üyesi Melikşah TURAN'a sonsuz teşekkürlerimi sunarım.

Her daim yanımda olan ve desteğini esirgemeyen biricik aileme ve arkadaşlarıma da çok teşekkür ederim.

**Nurcan ŞİMŞEK**  
**GÜMÜŞHANE – 2022**

## ÖZET

Doğa kaynaklı afetlerden biri olan depremlerden sonra hasarlı yolların belirlenmesi ve hasar görmemiş uygun yolların bulunması, kurtarma işlemlerinin yürütülmesinde, insanların etkilenen bölgeden en kısa sürede tahliyesinde ya da insani yardım malzemelerinin bölgeye sevk edilmesinde hayati önem taşımaktadır. Günümüzde kullanılan geleneksel insan gözlemi ve uydu görüntüleri ile yapılan yol hasarı değerlendirmeleri zaman alıcı ve maliyetli olmalarının yanı sıra sadece yollarda bulunan hasarları inceleyerek afet bölgelerine ulaşabilmek için trafik geçişi hakkında herhangi bir bilgi içermemektedirler.

Bu çalışmada; depremlerden sonra meydana gelen yol hasarlarının otomatik belirlenip afet bölgelerine yakın başka bir güzergâhın belirlenmesi için evrişimli sinir ağı ve klasik en kısa yol algoritmasının birbirine entegrasyonu ile hızlı ve verimli bir hibrit taşıma sistemi oluşturulmuştur. CNN algoritması hasarlı ve hasarsız olmak üzere toplamda 552 yol görüntülerinden oluşan veri setinde eğitilerek VGG-16 mimarisi ile gerçekleştirilen test sonrasında %97 oranında doğruluk elde etmeyi başarmıştır. CNN algoritmasının açık yol ve kapalı yol olarak yapmış olduğu tahminler ile klasik en kısa yol algoritması üzerinden hasar gören yollar, kullanılan ceza terimi ile çıkartılıp tüm kullanılabilir güzergâhlar arasından en kısa mesafeli olan güzergâh belirlenmiştir. Bu iki algoritmanın birbirine entegrasyonu ile hızlı ve verimli bir hibrit taşıma sistemi oluşturularak başarılı sonuçlar elde edilmiştir.

**Anahtar Kelimeler:** Afet, Deprem, Evrişimli sinir ağı, Klasik en kısa yol algoritması, Yol hasarı

## SUMMARY

After earthquakes, which is one of the natural disasters, identifying damaged roads and finding suitable undamaged roads are of vital importance in carrying out rescue operations, evacuating people from the affected area as soon as possible or dispatching humanitarian aid materials to the region. Road damage assessments made with traditional human observation and satellite images used today are time consuming or costly and do not contain any information about traffic passage in order to reach disaster areas by only examining the damages on the roads.

In this study; a fast and efficient hybrid transportation system has been created by integrating the convolutional neural network and the classical shortest path algorithm to automatically determine the road damages that occur after earthquakes and to determine another route close to the disaster areas. The CNN algorithm is trained on a dataset consisting of a total of 552 road images, both damaged and undamaged. After the test performed with the VGG-16 architecture, it managed to achieve 97% accuracy. With the predictions made by the CNN algorithm as 'open road' and 'closed road', the damaged roads over the classical shortest path algorithm were removed with the penalty term used and the route with the shortest distance was determined among all available routes. Successful results were obtained by creating a fast and efficient hybrid transport system with the integration of these two algorithms.

**Keywords:** Classical shortest path algorithm, Convolutional neural network, Disaster, Earthquake, Road damage

## İÇİNDEKİLER

KABUL VE ONAY .....	III
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	IV
TEŞEKKÜR.....	V
ÖZET.....	VI
SUMMARY .....	VII
İÇİNDEKİLER .....	VIII
TABLOLAR DİZİNİ .....	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ .....	XIII
1. GİRİŞ .....	1
1.1. Temel Kavramlar, Afet Türleri ve Afet Yönetimi .....	2
1.1.1. Olay, Acil Durum ve Afet.....	2
1.1.2. Afetlerin Sınıflandırılması .....	6
1.1.3. Doğa Kaynaklı (Doğal) Afetler.....	7
1.1.4. Teknolojik ve İnsan Kaynaklı Afetler.....	10
1.1.5. Türkiye'nin Afetselliği.....	12
1.1.6. Afet Yönetimi.....	14
1.1.7. Afet Öncesi.....	15
1.1.8. Afet Sırası .....	15
1.1.9. Afet Sonrası.....	16
1.1.10. Afet Yönetim Evreleri.....	16
1.1.11. Afet Risk Yönetimi .....	17
1.1.12. Afet Kriz Yönetimi .....	19
1.2. Deprem .....	20
1.2.1. Deprem ve Deprem Türleri .....	20
1.2.2. Deprem Şiddeti ve Büyüklüğü.....	22
1.2.3. Türkiye'nin Depremselliği .....	24
1.2.4. Depremlerden Sonra Ortaya Çıkan İkincil Afetler .....	26
1.3. Yapay Zekâ .....	27
1.3.1. Yapay Zekâ Kavramı .....	27
1.3.2. Yapay Zekânın Kısaca Tarihi Gelişimi.....	29
1.3.3. Yapay Zekâ Teknikleri (Uygulamaları).....	31

1.3.4. Makine Öğrenmesi .....	33
1.3.5. Derin Öğrenme .....	35
1.3.6. Aktarmalı (Transfer) Öğrenme .....	45
1.3.7. Afet Yönetimi Alanında Yapay Zekâ Kullanımı .....	46
1.4. En Kısa Yol Algoritması .....	50
2. LİTERATÜR ÖZETİ .....	53
2.1. Deprem Sonrası Meydana Gelen Yol Hasarları .....	53
2.2. Yol Hasar Tespiti İle İlgili Yapılan Çalışmalar .....	54
3. MATERYAL VE YÖNTEMLER.....	58
3.1. Problemin Durumu.....	58
3.2. Araştırmanın Amacı .....	58
3.3. Araştırmanın Önemi.....	59
3.4. Araştırmanın Özgün Değeri ve Literatüre Katkısı .....	60
3.5. Araştırmanın Kapsamı .....	60
3.6. Araştırmanın Kısıtlılıkları .....	60
3.7. Araştırmanın Modeli .....	60
3.8. Veri Toplama Araçları ve Yöntemleri .....	61
4. BULGULAR VE TARTIŞMA .....	63
4.1. İkili Sınıflandırmanın Bulguları ve Yorumları .....	63
4.2. CNN Modeli İle Klasik En Kısa Yol Algoritmasının Birbirine Entegrasyonu.....	66
4.3. Tartışma .....	68
5. SONUÇ VE ÖNERİLER .....	71
KAYNAKÇA .....	73
ÖZGEÇMİŞ .....	84

## TABLULAR DİZİNİ

Tablo 1. Afetlerin sınıflandırılması (URL-3, 2021).....	7
Tablo 2. 2017-2020 yılları arası meydana gelen doğal afet sayısı ve etkileri (CRED, 2020; CRED, 2019; CRED, 2018; CRED, 2017).....	8
Tablo 3. 2020 yılında afetlerden etkilenen kişi sayısı (URL-6, 2020).....	14
Tablo 4. Büyüklüklerine göre depremler ve magnitüdüleri (Özdemir, t.y.: 71). ....	23
Tablo 5. Büyüklük ve şiddet karşılaştırması ( Baxter, 2000: 7). ....	24
Tablo 6. Yapay zekâ tarihinin kronolojisi (Yılmaz, 2017: 18). ....	30
Tablo 7. Afet yönetiminde büyük veri uygulamaları (Arslan vd., 2018: 5-6). ....	48
Tablo 8. VGG-16 modelinin eğitim ve doğrulama setindeki performansı .....	64
Tablo 9. Test veri seti için karışıklık matrisi sonuçları.....	64
Tablo 10. Modelin test setindeki performansı.....	65
Tablo 11. Duyarlılık, özgüllük ve G-ortalama açısından modelin performansı .....	66
Tablo 12. A ile B arasındaki herhangi bir yolda hasar meydana gelmediği durumda en kısa yolun belirlenmesi .....	67
Tablo 13. A ile B arasındaki bir yolda hasar meydana geldiğinde CNN algoritmasının tahmini ve en kısa yolun belirlenmesi.....	68

## ŞEKİLLER DİZİNİ

Şekil 1. Olay, acil durum ve afet ( İSMEP, 2014'den aktaran Şahin, 2017: 7). ....	3
Şekil 2. Afetlerin neden olduğu kayıplara göre sınıflandırılması (Kadioğlu, 2008: 9)....	4
Şekil 3. Afet türleri (AFAD, 2021). ....	6
Şekil 4. Afet türleri ve afet türlerine göre ölüm oranı (CRED ve UNDRR, 2020).....	8
Şekil 5. Türkiye'de son 21 yılda meydana gelen insan kaynaklı afetler (URL-4, 2021).11	
Şekil 6. Türkiye'de 2000-2021 yılları arası meydana gelen doğal afet türleri(a). Can kayıbı sayısı(b) (URL-5, 2021). ....	13
Şekil 7. 2020 yılında Türkiye'de meydana gelen doğa kaynaklı olaylar (AFAD, 2020). .....	13
Şekil 8. Afet yönetim sistemi evreleri (Kadioğlu, 2008: 12). ....	17
Şekil 9. Depremlerin etkileri (UKessays, 2018). ....	21
Şekil 10. Deprem tehlike haritası (URL-7, 2021). ....	25
Şekil 11. 1990 ile 2021 yılları arasında Türkiye'de M: 5 ve üzeri depremler (URL-8, 2021). ....	26
Şekil 12. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo'dan aktaran Öztürk ve Şahin, 2018: 28). ....	33
Şekil 13. Makine öğrenmesinin kullanıldığı bazı uygulamalar (URL-10, 2021). ....	35
Şekil 14. Derin öğrenme mimarileri (Şeker vd., 2017).....	37
Şekil 15. Tekrarlayan sinir ağı mimarisi (Hao vd., 2016: 423).....	37
Şekil 16. (a) Derin inanç ağı. (b) Sınırlı boltzmann makinesi (Hao vd., 2016). ....	38
Şekil 17. Otomatik kodlayıcı mimarisi (Hao vd., 2016: 430). ....	39
Şekil 18. Evrişimli sinir ağının kavramsal yapısı (Hidaka ve Kurita, 2017: 161). ....	39
Şekil 19. Evrişimsel bir sinir ağının farklı katmanları (Hao vd., 2016: 421).....	41
Şekil 20. Tam bağlantı katmanı mimarisi (Doğan ve Türkoğlu, 2019: 418). ....	42
Şekil 21. VGG-16 mimarisi (Tammina, 2019: 146). ....	44
Şekil 22. Geleneksel makine öğrenimi ve transfer öğrenimi arasındaki öğrenme süreçlerinin karşılaştırmalı diyagramı (Tammina, 2019: 143). ....	46
Şekil 23. Teknoloji tabanlı afet yönetim şeması (Memiş ve Babaoğlu, 2020: 787). ....	47
Şekil 24. Yıllara göre afet yönetimi alanında yapılan yapay zeka çalışmaları (Sun vd., 2020: 7). ....	50
Şekil 25. Basit bir graf modeli .....	51
Şekil 26. Maliyetli graf (a) ve komşuluk matrisi (b) örneği (Günbatar, 2008: 9).....	51

Şekil 27. 12 Kasım 1999 Düzce depremi E-5 Bolu geçişi karayolu hasarı (Balyemez ve Berköz, 2005: 4).....	53
Şekil 28. Kocaeli depremi viyadük çökmesi (Sucuoğlu, 2000: 10).....	54
Şekil 29. Araştırmanın modeli .....	61
Şekil 30. Hasarlı ve normal yolları içeren veri örnekleri.....	62
Şekil 31. VGG-16 modelinin epoch (eğitim turu) sayısına göre eğitim ve doğrulama kaybının değerleri .....	63
Şekil 32. Karışıklık matrisi çizimi .....	64
Şekil 33. Modelin ROC eğrisi.....	65
Şekil 34. Hibrit model örneği.....	67



## SİMGELER VE KISALTMALAR DİZİNİ

AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
CNN	: Evrişimli sinir ağları
CRED	: Afetlerin epidemiyolojisi araştırma merkezi
EM-DAT	: Acil durum veri tabanı
IFRC	: Uluslararası Kızıllaç/Kızılay toplulukları federasyonuna
M	: Ceza deęişkeni
R-CNN	: Bölge tabanlı evrişimli sinir ağı
S	: Kaynaklar
SVM	: Destek vektör makineleri
X	: Ağıdaki kenar
W	: Karşılık gelen kenarın ağırlığı



## 1. GİRİŞ

Afetler meydana geldikleri bölgelerde, can ve mal kayıplarına yaralanmalara, eğitim ve sağlık gibi temel hizmetlerin aksamasına, ulaşım-altyapı tesislerinde bozulmalara sebebiyet vererek bölgenin ekonomik ve sosyal düzeninde ağır hasarlar oluşturmaktadır (Ergünay, 2009a: 5). Yüz yıllar boyunca ölümlere ve ağır hasarlara sebep olan doğal afetler günümüzde de sayıları, etki alanları, etki süreleri ve şiddetleri günden güne artış göstermektedir (Noji, 1991: 271; Ural ve Özmen, 2014: 4). 2020 yılında tüm dünyada meydana gelen doğal afetlerde 98.4 milyon kişi etkilemiş ve 171.3 milyar dolarlık bir ekonomik kayıp meydana gelmiştir (CRED, 2020). Dünya genelinde doğa kaynaklı afet olarak en çok görülen olaylar meteorolojik olaylar olarak karşımıza çıksa da en ölümcül ve ekonomik kaybı en yüksek olan afetler olarak depremler karşımıza çıkmaktadır (CRED ve UNDRR, 2020: 6). Gelişen teknolojiler ile depremlerin meydana gelmesi önleyemezken bu teknolojilerin afet yönetiminin tüm evrelerinde kullanılması ile etkili, hızlı ve verimli bir afet yönetimi gerçekleştirilmesine olanak sağlayacaktır. Büyük verilerin ortaya çıkmasıyla afet yönetimi alanında büyük veri oluşturan uydu görüntüleri, insansız hava araçları, nesnelerin interneti, sosyal medya içerikleri ve uzaktan algılama sistemleri gibi birçok kaynak kullanılmaktadır (Memiş ve Babaoğlu, 2020: 166). Afet yönetiminde büyük veri kaynakları entegre edildiğinde verilerin manuel analiz edilip işlenmesi mümkün değildir. Bu hacimli verilerden yararlı ve güvenilir bilgilerin çıkarılıp analiz edilmesi yapay zeka yöntemleri ile mümkün hale gelerek afet yönetiminde etkili bir karar destek sisteminin oluşmasını sağlamaktadır (Sun vd., 2020: 2).

Yapay zekâ uygulamaları ilk olarak insan beyninden esinlenerek ortaya çıkmış olsa da yeni geliştirilen yöntemler ve uygulamalar insan gözlemlerinden daha başarılı sonuçlara ulaşmaktadırlar. Yapay zeka yöntemleri afet durumlarında analizleri hızlandırarak optimal müdahale stratejilerinin belirlenmesine yardımcı olmaktadır. Günümüzde afet öncesinde tahminlerin yapılmasında, afet sırasında eğitilen modeller ile sel hasarının belirlenmesi, deprem hasarlarının belirlenmesi, afet sonrasında sosyal medya verileri ile ihtiyaç sahiplerinin belirlenmesi gibi alanlarda kullanılarak doğruluğu yüksek olan sonuçlar elde edilmiştir (Yu vd., 2018: 15). Afetlerden sonra yol hasarlarının değerlendirilmesi ile ilgili yapılan çalışmalar da literatürde mevcuttur. Bu çalışmalar genellikle uzaktan algılama sistemleri ve uydu görüntüleri verileri ile yapay zeka uygulamalarının gerçekleştirildiği çalışmalardır (İzadi vd., 2017; Yang vd., 2019).

Bu çalışmada, insansız hava araçlarına veya dronlara takılan kameralar ile yol hasar tespitinin yapılması ve afet bölgelerine en kısa zamanda erişimin sağlandığı hasarsız diğer yolların belirlenmesi amaçlanmıştır. Yapay zekâ alt dalı olan derin öğrenme mimarileri içerisinde evrimsel sinir ağları kullanılarak hasarlı ve hasarsız yolları belirleyebilen bir model oluşturulmuştur. Bu model ile belirlenen hasarlı yollar eklenen ceza terimi ile klasik en kısa yol algoritması üzerinden çıkarılarak afet bölgesine en yakın güzergâh belirlenmeye çalışılmıştır. Oluşturulan model ile afet bölgesine en yakın ve hasar görmemiş yollar yüksek doğruluk ile belirlenmiştir. Çalışma günümüzde geleneksel yöntemler ile yapılan yol hasar tespit çalışmalarına göre zaman ve doğruluk açısından avantaj sağlayacaktır. Yol hasarı tespiti sonrasında rotalama yapan ilk çalışma olarak da bu alanda yapılan çalışmalara öncü nitelikte olacaktır.

## **1.1. Temel Kavramlar, Afet Türleri ve Afet Yönetimi**

### **1.1.1. Olay, Acil Durum ve Afet**

#### **1.1.1.1. Olay**


Meydana geldiği bölgede çok küçük bir alanı etkisi altına alan olaylardır. Bu olayların meydana gelmesi sonucunda bölgede bulunan kurum ve kuruluşların olağan işleyiş düzenini etkilemediği gibi, olayın sıfırıncı anından itibaren ilk müdahale edenler tarafından kontrol altına alınabilmektedir (URL-1, 2021).

#### **1.1.1.2. Acil Durum**

18.12.2013 tarihinde ve 28855 sayılı Resmi Gazete’ de yayımlanan Afet ve Acil Durum Müdahale Yönetim Hizmetleri Yönetmeliğine göre acil durum; toplumun tamamı veya belli kesimleri için gündelik yaşam ve faaliyetlerini sonlandıran veya sekteye uğratan ivedilikle acil müdahale gerektiren olaylar ve bu olaylara sebep olan kriz halidir (Afet ve Acil Durum Müdahale Yönetim Hizmetleri Yönetmeliği, 2013).

Acil durumlar, afetten etkilenen topluluğun başa çıkma yeteneğinin alt üst olmasıyla daha fazla yaşam ve geçim kaybını önlemek için hızlı ve etkili eylemlerin gerekli olduğu durumlar olarak ifade edilmiştir (Wisner ve Adams, 2002: 5).

Afet yönetimi alanında sıklıkla kullanılan ve meydana gelen olayların etkilediği alan, kişi sayısı yada insanların bu olaylarla başa çıkma kabiliyetlerine göre Şekilde 1’de görüldüğü gibi farklı kavramlar ele alınmaktadır.



Şekil 1. Olay, acil durum ve afet ( İSMEP, 2014'den aktaran Şahin, 2017: 7).

### 1.1.1.3. Afet

Açıklamalı Afet Yönetimi Terimleri Sözlüğü'ne göre afet; meydana geldiği bölgedeki toplumun tamamı veya belirli kesimleri için sosyal, fiziksel ve ekonomik kayıplara yol açan, gündelik devam eden hayatı ve insan faaliyetlerini durduran ya da sekteye uğratan, etkilediği bölgedeki insanların başa çıkma kapasitesinin yetersiz kaldığı teknoloji, doğa veya insan kökenli olaylardır (AFAD, 2014).

Afet kavramının Uluslararası Kızıllaç/Kızılay Toplulukları Federasyonuna (IFRC) göre tanımı; toplumun işleyişinde büyük aksaklıklara sebep olan sosyal, ekonomik ve çevresel kayıpları toplum kendi kaynaklarını kullanarak başa çıkamadıkları olaylardır (IFRC, 2021).

Afetler etkilenen toplumun kendi kaynaklarını kullanarak başa çıkma yeteneğinin yetersiz kaldığı; ekonomik, sosyal ve çevresel kayıplara sebebiyet veren veya toplumun işleyişinde ciddi bir bozulmaya neden olan olaylardır. Afetler genellikle şunların kombinasyonunun bir sonucu olarak tanımlanır: Bir tehlikeye maruz kalma, mevcut güvenlik açığı koşulları ve olumsuz sonuçları azaltmak ya da bunlarla başa çıkmak için yetersiz kapasite veya yeterli önlemlerin alınmamasıdır (UNISDR, 2009: 9).

Afet arz ve talep arasındaki dengesizliği içeren, sosyal dokunun bozulduğu ve işlevsiz hale geldiği durumlardır (Alexander, 2005: 27–98). Afetler bir olayın sebebi değil, doğurduğu sonuçtur. Afetlerin büyüklüğünü toplumun savunmasızlığı ve insanlar üzerinde sebep olduğu can ve mal zayıfları ile belirlenmektedir (Kadıoğlu, 2008: 6).

Afetler ortaya çıktıklarında toplum üzerinde ekonomik, sosyal ve fiziksel kayıplara sebebiyet vermesi gerekmektedir. Bu kayıplar afetin ortaya çıktığı bölgenin özelliklerine, bölgede yaşayan halkın bu afetlere karşı deneyiminin olup olmamasına ve yapı stokunun durumuna bağlı olarak değişim göstermektedir. Afet tanımlarına

bakıldığında bir olayın afet durumuna dönüşmesi afetin meydana geldiği toplumun gelişmişlik düzeyine ve afet kültür algısına bağlıdır (Tercan, 2018: 103).

Bir olayların afet olarak kabul edilebilmesi için Afetlerin Epidemiyolojisi Araştırma Merkezi (CRED)'ne göre aşağıdaki kriterlerden en az bir tanesinin gerçekleşmesi gerekmektedir.

- 10 veya daha fazla kişinin yaşamını yitirmesi,
- 100 veya daha fazla kişinin afetzede olması,
- Ülke genelinde olağanüstü hal ilan edilmesi,
- Ülkedeki kurum ve kuruluşların yetersiz kalması ve uluslararası yardım çağrısında bulunulması (EM-DAT, 2021).

Afetlerin büyüklüğü çevreye verdiği tahribatlarla can kayıplarıyla, ekonomik ve kültürel kayıplarla ölçülmektedir (Kadioğlu, 2008: 6). Afetlerin boyutu sebep olduğu kayıp ve hasarlar ile üç kategoride incelenmektedir.



Şekil 2. Afetlerin neden olduğu kayıplara göre sınıflandırılması (Kadioğlu, 2008: 9).

Afetlerin büyüklüğüne etki eden faktörler şu şekilde sıralanabilir.

- Olayın fiziksel büyüklüğü,
- Olayın yapı ve nüfus bakımından yoğun olan yerleşim alanlarına uzaklığı,
- Fakirlik, gelişmişlik seviyesinin düşük olması ve işsiz kişi sayısının fazla olması,
- Afet tehlikesi bulunan bölgelerde hızlı ve denetimsiz yapılaşma, şehirleşme ve sanayileşme,
- Ormanlık alanların ya da çevrenin bilinçsiz olarak veya kasten tahrip edilmesi ve yanlış kullanımı,
- Bilgisizlik ve eğitim eksikliği,

- Toplumun afet olaylarına karşı önceden alabildiği koruyucu ve önleyici önlemlerin ulaşabildiği düzey olarak belirlenmektedir (Ergünay, 2009b: 4).

Tanımlardan da yola çıkarak afetlerin ortak özelliklerini şu şekilde sıralayabilmek mümkündür.

- Meydana geldikleri bölgedeki insanlar üzerinde can ve mal kayıplarına neden olurlar.
- İnsanların yaşam kaynaklarından olan su, yiyecek, enerji ve yakıt tesislerine önemli hasarlar meydana getirirler.
- Meydana geldiği bölgede insanlar üzerinde paniğe neden olarak kargaşa ve kaos ortamının oluşmasına sebebiyet verirler.
- Bölgedeki insanların yaralanmasına, sakat kalmasına ve psikolojik olarak ağır travmalara neden olurlar.
- Afetler meydana çıktığı ilk anda koordineli bir afet yönetimi yapılamayabilir.
- Afetlerden sonra temiz tutulmayan toplanma alanları ve barınma merkezleri salgın hastalıklara sebep olabilir.
- Sağlık hizmetlerinde aksamalar meydana getirir.
- Ulaşım ve altyapı tesislerinde aksaklıklara ya da bozulmalara neden olur.
- Bölgeye yapılan yatırımları olumsuz etkiler ve bölgenin gelişme hızını yavaşlatır.
- Acil durum personelleri afet bölgesinde afetzede durumunda olduklarından dolayı bu kurum ve kuruluşlar ilk anda kendi kapasiteleri yetersiz kalabilir.
- Afetler insanların hazırlıksız olarak yakalandıkları için büyük maddi kayıplara sebebiyet verirler.
- Bazı afetlerin ne zaman ve nerede olacağı tahmin edilebilirken bazı afetler tahmin edilmesi güçtür.
- Bazı afetlerin meydana gelmesi yıllar sürerken bazı afetler aniden meydana gelebilir (Çeber, 2005:7; Ergünay, 2002'den aktaran, Özmen, 2018b: 7; Hanilçı, 2018: 8-9).

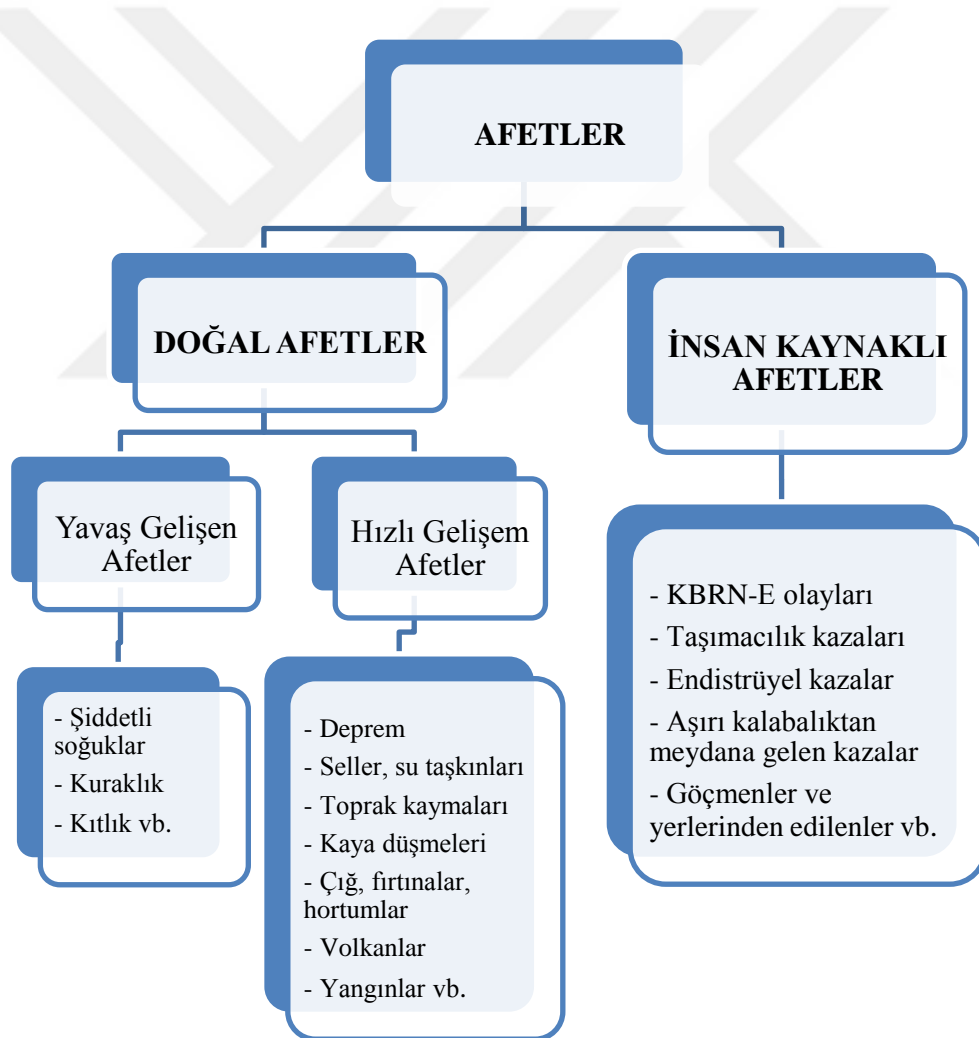
Afetler meydana geldikleri bölgelerde domino etkisi yaratarak:

- a) Doğrudan can ve mal kayıplarına, yaralanmalara ve alt yapı hasarlarına,
- b) Dolaylı olarak üretim tesislerinin kapanmasına ya da üretimin durmasına, sağlık, eğitim ve kamu hizmetlerinin aksamasına, üretim veya hizmetlerin talebin altında kalmasına, göç ve kimsesiz kalan insanların sosyal düzenin bozulmasına,

c) İkincil etkiler olarak ise hızlı şehirleşme, tüm kaynakların afet bölgesine iletilmesi ile aşırı talep ve fiyat artışı, afet bölgelerine yapılan yatırımların aksaması gibi etkiler ortaya çıkmaktadır (Ergünay, 2009a: 5).

### 1.1.2. Afetlerin Sınıflandırılması

Afetler kaynağına, oluş zamanına ve oluş hızına göre farklı olarak sınıflandırılabilir. Afet ve Acil Durum Yönetim Başkanlığına göre afetler doğa kaynaklı afetler ve insan kaynaklı afetler olarak sınıflandırmıştır. Afetler olduğu bölgenin ekonomik, sosyal, coğrafi özelliklerine ve meydana gelme sıklığına göre ülkeden ülkeye farklılıklar göstermektedir. Dünya genelinde en fazla meydana gelen afet türleri olarak meteorolojik afetler karşımıza çıkmaktadır (URL-2, 2021).



Şekil 3. Afet türleri (AFAD, 2021).

EM-DAT veri tabanına göre ise afetler doğal afetler ve teknolojik afetler olarak ikiye ayrılmaktadır.

Tablo 1. Afetlerin sınıflandırılması (URL-3, 2021).

Afet Grubu	Afet Alt Grubu	Afet Türü
Doğal Afetler	Jeofizik	Kütle hareketleri
		Volkanik faaliyetler
	Meteorolojik	Fırtına
		Sis
		Aşırı sıcaklık
	Hidrolojik	Heyelan
		Sel
	Klimatolojik	Dalga hareketleri
		Kuraklık
		Yangın
	Biyolojik	Buzul gölü patlaması
		Epidemi
		Böcek istilası
	Teknolojik Afetler	Dünya dışı
Meteor çarpması		
Endüstriyel kaza		Uzay havası
		Kimyasal dökülme
		Çöküş
		Patlama
		Yangın
		Gaz sızıntısı
		Yağ sızıntısı
Zehirlenme		
Çeşitli kazalar	Radyasyon	
	Diğer	
	Çöküntü	
	Patlama	
	Yangın	
Ulaşım kazaları	Diğer	
	Hava yolu kazaları	
	Kara yolu kazaları	
	Demir yolu kazaları	
		Deniz yolu kazaları

### 1.1.3. Doğa Kaynaklı (Doğal) Afetler

Doğal afetler deprem, kasırga, sel, tsunami, hortum ve aşırı sıcaklık gibi kaynağını doğadan alan olaylardır. Yüz yıllar boyunca doğa kaynaklı olaylar ölümlere ve ağır hasarlara neden olmuşlardır (Noji, 1991: 271). Milyonlarca insanı etkileyen doğa kaynaklı olaylar günümüzde de sayıları, şiddetleri, etkili oldukları alan, etki süresi günden güne artış göstermektedir (Ural ve Özmen, 2014: 4).


Doğal afetlerin etkisi yoksulluk, bilgisizlik, hafifletici ya da afetlerden önce iyileştirici önlemler alınmaması ile birlikte kırılganlıkları nedeniyle afetlerle başa çıkma kapasitesi yetersiz olan az gelişmiş veya gelişmekte olan ülkelerin nüfusu ve ekonomisi üzerinde ciddi bozulmalara ve kayıplara neden olmuştur (Jayaraman, 1997: 293).

Tablo 2. 2017-2020 yılları arası meydana gelen doğal afet sayısı ve etkileri (CRED, 2020; CRED, 2019; CRED, 2018; CRED, 2017).

Yıl	Bildirilen Afet Sayısı	Toplam Ölü Sayısı	Etkilenen İnsan Sayısı (Milyon)	Ekonomik Kayıp (Milyar US\$)
2020	389	15.08	98.4	171.3
2019	396	11.755	94.9	103
2018	315	11.804	68.5	132
2017	335	9.697	96	334

Afetlerin Epidemiyolojisi Araştırma Merkezinin (CRED) 2017 ile 2020 arasındaki dünya genelinde meydana gelen doğal afet raporları ile afetlerin insanlara ve ekonomiye vermiş olduğu kayıplar Tablo 2’de listelenmiştir.

EM-DAT veri tabanına göre son yirmi yılda dünya çapında 7348 doğal afetler kaydedilmiştir. Bu afetler 1.23 milyon insanın yaşamını sonlandırırken 4 milyardan fazla insanı etkileyip 2.97 trilyon ABD doları tutarında ekonomik kayba yol açmıştır. Şekil 4’te son yirmi yılda sıklıkla meydana gelen afetler ve bu afetlerde hayatını kaybeden insanların oranı yüzdeler halinde gösterilmiştir (CRED ve UNDRR, 2020: 6).



Şekil 4. Afet türleri ve afet türlerine göre ölüm oranı (CRED ve UNDRR, 2020).

### **1.1.3.1. Sel**

Bir akarsuyun bazı nedenlerden dolayı yatağından etrafa taşarak bölgede bulunan alt yapılara, yerleşim yerlerine, tarım arazilerine ve canlılara zarar verecek büyüklükte akış meydana getirmesi sel olarak tanımlanmaktadır (Uşıkay ve Aksu, 2002: 133).

Seller aşırı yağışlarla, buzul ve karların aniden erimesiyle, baraj ve göletlerde meydana gelen çökme ya da taşmalarla, akarsu yataklarının doğal ya da insanlar tarafından akış kesitlerinin daralması, kıyıların iç kısımlarında oluşan depremler veya volkanik patlamalar sonucu oluşan büyük dalgalar ve sel riski bulunan yerlerde kontrolsüz yapılaşma sonucunda meydana gelmektedirler (Özmen, 2015: 27).

Literatürde seller oluşum sürelerine ve oluşum yerlerine göre şu şekilde yer almaktadır.

Oluşum sürelerine göre seller:

- Yavaş gelişen seller: Bir hafta veya daha uzun sürede meydana gelirler.
- Hızlı gelişen seller: Bir veya iki gün içinde oluşmaktadır.
- Ani gelişen seller: 6 saat içinde oluşabilen sellerdir.

Oluşum yerlerine göre seller:

- Şehir selleri,
- Kıyı selleri
- Dere ve nehir selleri,
- Kuru vadi (dağlık alan) selleri,
- Baraj selleri olarak sıralanabilir (Kadioğlu ve Özdamar, 2008: 255).

### **1.1.3.2. Tsunami**

Kökeni Japoncadan gelen tsunami Türkçede liman dalgası olarak adlandırılmaktadır. Tsunamiler deprem, heyelan ve yanardağ gibi doğal afetler sonucunda deniz tabanında meydana gelen çökmeler ya da levha hareketleri ile deniz suyunun dalgalar halinde metrelerce yükselmesiyle oluşur. Kıyı kesimlerde bulunan yerleşim yerlerine ulaşan dalgalar bölgede ağır hasarlar meydana getirirler (Tanırca vd., 2017).

### **1.1.3.3. Heyelan**

Heyelanlar yer çekiminin etkisiyle kayalardan, topraklardan ve döküntülerden oluşmuş kütlelerin yerlerinden koparak aşağıya doğru hareket etmesiyle oluşan olaylardır (Öztürk, 2002: 38). Heyelanlar farklı dış faktörler tarafından oluşan

olaylardır. Bu faktörlere baktığımızda karşımıza hazırlayıcı faktörler ve tetikleyici faktörler çıkmaktadır. Hazırlayıcı faktörler toprağın yapısal özellikleri, yer altı suyunun koşulları, yamacın eğimi, bitki örtüsü ve arazinin kullanımı. Tetikleyici faktörler ise deprem, yağış ve insan gibi etmenler heyelan oluşumuna neden olmaktadır (Tarım ve Orman Bakanlığı, 2016: 8). Ülkemizde heyelanların en fazla Doğu Karadeniz Bölgesinde görülmesinin sebepleri yıllık yağışlı gün sayısının fazla olması, eğimli, dik arazi yapısının olması ve tarım arazilerinin yanlış kullanılmasıdır (Altun vd., 2016: 491).

Heyelanlar dünya çapında en önemli üçüncü doğal afet olarak kabul edilmektedir. Heyelanların uyarı süresi çok kısa olmasından dolayı insanların bölgeyi tahliye edebilmesi için zamanları olmamakta ya da kısa bir zaman dilimleri bulunmaktadır. Bu nedenle heyelanlar meydana geldikleri alanda insanlara, hayvanlara, konutlara, alt yapılara ve tarım arazilerine önemli ölçüde zarar vermektedir (Perera vd., 2018: 1–2).

#### **1.1.3.4. Çığ**

Çığ genellikle dağlık alanlarda eğimin fazla olduğu bitki örtüsünün olmadığı yamaçlarda biriken kar kütesinin hızla aşağıya doğru hareket etmesidir. Ülkemizde çığ olayları en fazla Kuzey ve Doğu Anadolu'nun dağlık kesimlerinde oluşmaktadır (Kızıloğlu, Okuroğlu ve Örüng, 2006: 57).

#### **1.1.3.5. Kaya Düşmesi**


Bozulmuş veya parçalanmış farklı boyutlarda kayaların deprem, aşırı yağış gibi fiziksel ya da kimyasal etmenler sonucu bulunduğu alandan koparak aşağıya doğru hareket etmesidir (AFAD, 2014: 99). Ülkemizde kaya düşmeleri genellikle İç Anadolu bölgesi ile Doğu Anadolu bölgesinde görülmektedir (Ergünay, 2007: 9).

#### **1.1.4. Teknolojik ve İnsan Kaynaklı Afetler**

İnsan kaynaklı afetler büyük hasarlara ve sosyal bozulmalara sebep olan, birden fazla paydaşı içeren ve teknolojik, örgütsel ve sosyal süreçlerle ortaya çıkan olaylardır (Shaluf vd., 2002: 380). İnsan aktivitelerinden kaynaklanan ani veya uzun vadeli olarak oluşabilen doğal olmayan afet olayları olarak ifade edilebilir. Ani olarak meydana gelen insan kaynaklı afetler herhangi bir dış kuvvet olmadan bağımsız olarak meydana gelen maden çökmesi gibi olayları içerir. Uzun vadeli insan kaynaklı afetlere ise ulusal ve

uluslararası çatışmalar örnek verilebilir. Ayrıca tüm ulaşım kazaları da insan kaynaklı afetlerdir (Shaluf, 2007: 705).

Sanayileşme ve teknolojinin gelişmesiyle birlikte kimyasal dökülmeler, patlamalar, gaz sızıntısı, radyasyon ve ulaşım kazaları gibi çeşitli kazalar ortaya çıkmıştır. EM-DAT veri tabanına göre dünya genelinde 1900 ile 2020 yılları arasında teknolojik afetler tüm afetlerin üçte birini (%36,4) oluşturmaktadır. EM-DAT veri tabanına 2000 ile 2019 yılları arasında dünyada meydana gelen 5143 teknolojik afet kaydedilmiştir ve bu afetlerin yaklaşık üçte ikisi (3532 afet) ulaşım kazası olarak rapor edilmiştir. Endüstriyel kazalar ise rapor edilen kazalar arasında %16'lık bir kısmını oluştururken 1,4 milyondan fazla kişiyi etkileyerek teknolojik afetler arasında en çok kişiyi etkileyen afet olarak rapor edilmiştir (CRED ve CRUNCH: 2020).



Şekil 5. Türkiye'de son 21 yılda meydana gelen insan kaynaklı afetler (URL-4, 2021).

EM-DAT veri tabanına göre (Şekil 5) Türkiye'de 2000 ile 2021 yılları arasında 82 ulaşım kazası, 11 muhtelif kaza ve 9 endüstriyel kaza meydana gelmiştir. İnsan kaynaklı bu afetler sonucunda ulaşım kazalarında 1822 kişi, muhtelif kazalarda 233 kişi ve endüstriyel kazalarda 147 kişi hayatını kaybetmiştir. Yirmi bir yılda en çok can ve mal kaybına sebep olan kazalar ulaşım kazaları olarak ön plana çıkmaktadır.

### 1.1.5. Türkiye'nin Afetselliđi

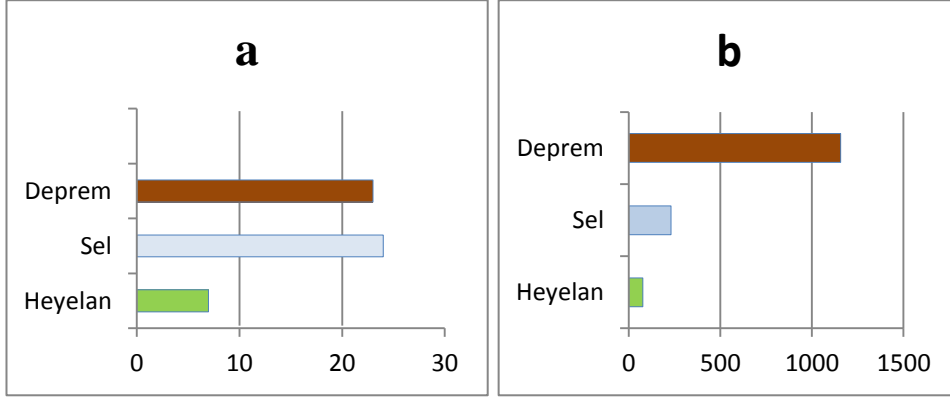
Türkiye tektonik oluşumu, jeolojik yapısı ve meteorolojik özelliklerinden dolayı geçmişten günümüze çeşitli doğal afetler meydana gelmiş ve meydana gelmeye de devam etmektedir. Türkiye'de deprem, sel, heyelan, erozyon, çığ ve kuraklık olaylarında büyük ölçüde can kayıpları, yaralanmalar ve maddi kayıplar verilmesi sonucunda olaylar afet boyutuna dönüşmektedir (TMMOB, 2007: 2).

Alp-Himalaya deprem kuşağında yer alan Türkiye'de çevreye ve insanlara vermiş olduğu yıkım ve hasarlardan dolayı ilk sırada depremler ve jeolojik afetler yer almaktadır. Ülkemizde insanlara ve yapılara hasar veren afetlerin yüzdelik dilimine baktığımızda %61'ini depremler, %15'ini heyelanlar, %14'ünü seller, %5'ini kaya düşmeleri%4'ünü yangınlar ve %1'ini meteorolojik olaylar oluşturmaktadır (Yılmaz, t.y.: 98).

Türkiye'de olasılık yöntemlerine göre beş yılda bir IX şiddetinde deprem olma ihtimali %63 olarak gösterilmektedir. Yıl içinde hasar meydana getiren depremlerin olma ihtimali de yine %63 tür (JICA, 2004: 8). Türkiye'de nüfusun %98'i deprem tehlikesi bulunan bölgelerde yaşamaktadır. Sanayi kuruluşlarının da %98'i deprem tehlikesi olan bölgelerdeyken %73'ü 1. derece aktif fay zonları bulunan alanlarda yer almaktadır. Aynı şekilde barajların %95'i ve enerji kaynaklarının %46 deprem tehlikesi bulunan alanlarda yer almaktadır (TMMOB, 2012: 1).


Son yıllarda kırsaldan kente göç olaylarının aratmasından dolayı kentlerde nüfus oranının ve bina sayısının artmasıyla alt yapı yetersizlikleri ya da dere yataklarına bilinçsiz olarak yapılan binalar sonucunda seller afet olarak ülkemizde ilk üç sırada yer almaktadır (Şengün ve Küçükşen, 2019: 199).

İklim değişikliği ve çevreye verilen hasarlardan dolayı su baskınları ve seller oluşma şekillerine veya sıklıklarına göre bölgeler arasında farklılık göstermektedir. Nehir tipi su baskınları genellikle 50 ila 100 yıl arasında tekrarlamakta ve erken uyarı sistemleri ve tahminlerle zararları minimize edilebilmektedir. Ancak meteorolojik şartlarla oluşan seller ve su baskınları çevrede ve insanlar üzerinde yıkıcı etkiler oluşturmaktadır (Ergünay, 2007: 6).



Şekil 6. Türkiye'de 2000-2021 yılları arası meydana gelen doğal afet türleri(a). Can kaybı sayısı(b) (URL-5, 2021).

EM-DAT veri tabanına göre (Şekil 6) son 21 yılda Türkiye'de en fazla meydana gelen afetler sel, deprem ve heyelan olarak kayıt altına alınmıştır. Kayıtlara göre Türkiye'de 21 yılda yirmi dört sel, yirmi üç deprem ve yedi heyelan olayı afet olarak kaydedilmiştir. Bu afetlerde en fazla can kaybı ise depremlerde yaşanmıştır.



Şekil 7. 2020 yılında Türkiye'de meydana gelen doğa kaynaklı olaylar (AFAD, 2020).

Şekil 7'de 2020 yılında Türkiye'de büyüklüğü 4.0'ın üzerinde olan 321 deprem, 107 heyelan, 17 kaya düşmesi, 177 sel/su baskınları, 2 obruk ve diğer afetler (fırtına, dolu, aşırı kış koşulları vb.) meydana gelmiştir.

Tablo 3. 2020 yılında afetlerden etkilenen kişi sayısı (URL-6, 2020).

<b>Afet Adı</b>	<b>Can Kaybı</b>	<b>Yaralı</b>
Elazığ (Sivrice) Depremi	41	1067
İzmir (Seferihisar) Depremi	114	1035
Giresun (Dereli) Seli	11	172
Van Bahçesaray Çığ Felaketi	41	53
Bingöl (Karlıova) Depremi	1	18
Sabiha Gökçen Havalimanı Uçak Kazası	3	180
Sakarya (Hendek) Havai Fişek Fabrika Patlamaları (2)	10	127
Van (Başkale) Depremi	9	37

Tablo 3 incelendiğinde Türkiye’de 2020 yılında en fazla can kaybına neden olan afet olarak karşımıza depremler çıkmaktadır. Ülkemizde depremlerde ölüm oranının yüksek olmasının nedeni kaçak ve denetimsiz yapılaşmanın yanı sıra plansız sanayileşme ile beraber kentlerin depremlere ve diğer afetlere karşı yeterince güvenli ve dayanıklı inşa edilmemesidir (Ural ve Özmen, 2014: 1).

#### **1.1.6. Afet Yönetimi**

AFAD Açıklamalı Afet Terimleri Sözlüğüne göre afet yönetimi; afetlerin etkilerini ve zararlarını azaltabilmek amacıyla afet öncesi hazırlık aşamasında, afet anı kriz yönetimi aşamasında ve afet sonrası rehabilitasyon (yeniden inşa) döneminde tüm gerekli önlemlerin alınması ya da yapılması gereken çalışmaların etkin olarak uygulanabilmesi için planlar yapılması ve koordineli şekilde uygulanabilmesi için tüm kurum ve kuruluşların imkan ve kaynaklarını hedefler ve öncelikler doğrultusunda kullanılmasını gerektiren çok disiplinli ve çok aktörlü karmaşık bir yönetim sürecidir (AFAD, 2014: 33).

Afetler insanlığın varoluşundan bu yana meydana geldikleri bölgeleri olumsuz olarak etkilemişlerdir. Buna karşılık insanlar hem bireysel hem de toplumsal olarak afetlerin kötü sonuçlarına maruz kalmayı önleyebilmek, afetlerin ilk etkilerini azaltabilmek ya da afet sonrası müdahale ve yeniden inşa için çeşitli önlemler geliştirmişlerdir. Tüm çabaların amacı afet yönetimini sağlayabilmektir (Coppola, 2006: 1).

Günümüzde insanlar gelişen teknoloji ile afetlere sebep olan deprem, fırtına ve volkanik patlamalar gibi doğa kaynaklı afetlerin oluşumunu engelleyememektedirler. Afetlerin etkilerini minimize edebilmek ve afetlere karşı dirençli toplumlar elde edebilmek için planlar hazırlamak ve uygulamaya geçirmek, insanları yaşadığı bölgelerin afetselliği hakkında bilgilendirmek veya afet zararlarını azaltacak tutumlar sergilemeleri için yapılan tüm çalışmalara afet yönetimi denilmektedir (Erkal ve

Değerliyurt, 2009: 151). Afet yönetiminin temel amacı afetlerin insanlara, toplumlara ve ekonomiye verdiği zararı azaltmaktır (Rao vd., 2007: 2).

Afet yönetimi, bir felaket olayı meydana geldiğinde uygulamaya konulan bir süreç veya stratejidir. Bu süreç normal hayatın sekteye uğradığında ve insan hayatının risk altında olduğu durumlarda başlatılabilir (Kale ve Kutemate, 2011: 35).

Afet yönetimi sağlık, eğitim ve imar gibi birçok alanı içine alan çeşitli kurum ve kuruluşların dâhil olduğu süreklilik arz eden dinamik ve çok disiplinli bir yönetim biçimidir (Akdağ, 2002: 6).

Afet yönetiminin amacı afetlerin zarar verme potansiyelini en aza indirerek afet etkilerini azaltmaktır. Afetlerin doğal çevreye, kültürel varlıklara ve tabiat varlıklarına vermiş olduğu zararı azaltarak toplumun ihtiyaç duyduğu kamu ve özel sektör hizmetlerinin afetlerden önceki normal sürece devam etmesini sağlamaktır (Şahin, 2019: 188).

Kapsamlı ve etkili bir afet yönetimi sağlayabilmek için afet öncesi, afet sırası ve afet sonrasında yapılması gerekenler şunlardır.

#### **1.1.7. Afet Öncesi**

- Meydana gelebilecek olaylardan bireylerin veya toplumun en az kayıpla ya da zararlarla kurtulabilmeleri için gereken tüm yasal ve idari önlemleri olay meydana gelmeden önce almak,
- Olayları önleyebilme imkânı varsa bu olayları afet boyutuna gelmeden önlemek eğer önlemek mümkün değilse, olay meydana geldiğinde ivedilikle arama, kurtarma çalışmalarını gerçekleştirip afet sonrası iyileştirme çalışmalarının hızlı ve verimli bir şekilde yapılmasını sağlamak,
- Toplumun her kesimi için afet kültürünün oluşturulabilmesi ve afetin etkilerinden en az zararlarla kurtulabilmek için eğitimler düzenlemek (Ergünay, 2009a: 30).

#### **1.1.8. Afet Sırası**

- Haberleşme ve ulaşımda meydana gelen aksaklıkları gidererek devamlılığını sağlamak,
- Afet bölgelerinde hızlı bir şekilde arama ve kurtarma çalışmalarına başlamak,
- Afetzedelerin binalardan ya da afet bölgesinden tahliyesini sağlayarak insanlara daha fazla zarar vermesini önlemek,

- Geçici barınma ve iskân alanları olan çadır kentlerin ya da konteyner kentlerin oluşturulmasını sağlamak,
- Afetzedelere yiyecek, içecek, giyecek ve yakıt ihtiyacı gibi temel yaşam malzemelerinin teminin sağlamak,
- Afetzedelere psikolojik destek için rehabilitasyon merkezleri oluşturmak,
- Kolluk güçleri ile bölgede her türlü güvenlik önlemini almak,
- Hasar tespit çalışmalarını başlatmak,
- Çevre sağlığı ve kültürel mirasları korumak için önlemler almak,
- Yangın, patlama ve salgın hastalıklar gibi ikincil afetleri önlemektir (Erkal ve Değerliyurt 2009: 152; Özmen vd., 2005).

#### **1.1.9. Afet Sonrası**

- En kısa sürede en fazla insan hayatını kurtarmak ve sağlıklarına kavuşmalarını sağlamak,
- Afetlerden sonra oluşabilecek tehlikelerden ve risklerden insanların hayatlarını ve mallarını korumak,
- Afetzedelerin hayati ihtiyaçlarını karşılamak ve hayatlarının en kısa sürede afet öncesindeki gibi normal hale getirilmesini sağlamak,
- Afetlerin yol açtığı sosyal, ekonomik, psikolojik ve çevresel kayıpları minimize etmek,
- Afet bölgesindeki yaraların bir an önce sarılmasını sağlamak,
- Afetlerden etkilenen kişiler ve toplumlar için daha güvenli ve risklerin azaltılmış olduğu yeni yaşam yerleri oluşturmaktır (Ergünay, 2009a: 30).

#### **1.1.10. Afet Yönetim Evreleri**

Modern afet yönetim sistemi hazırlık, zarar azaltma, müdahale ve iyileştirme gibi dört ana evreden oluşmaktadır. Afet yönetiminin tüm evreleri birbiri ile ilişkilidir. Bu evreler doğrusal değil döngüsel bir ilişki içindedir. Afetlerden önce hazırlıklı olunmalı ve afet anında hazırlanan planlar etkin bir şekilde uygulanmalı afet sonrasında ise yeniden inşa ve iyileştirme çalışmaları yapılarak bir önceki afetten çıkarılan dersler ve edinilen tecrübelerle başa dönerek hazırlık ve zarar azaltma çalışmaları yapılmalıdır (Kadıoğlu, 2011: 51–52).

Afet yönetimi döngüsü (Şekil 8) şu anlamları içermektedir.

- Afet yönetimi döngüsünün her evresinde yapılan ya da yapılmayan faaliyetler bir sonraki evrenin başarılı ya da başarısız olmasını etkiler.
- Her evre birbirini etkilediğinden dolayı afet yönetim sistemi, kapsamlı veya bütünlük afet yönetim sistemi olarak adlandırılmaktadır.
- Sistemin temelinde tüm tehlike ve riskleri değerlendirerek zarar azaltma ve hazırlık faaliyetlerini olaydan önce, kapsamlı ve birbiri ile entegre edilmesi yatmaktadır.
- Zarar azaltma ve hazırlık evrelerinin etkili uygulanamayışı müdahale ve iyileştirme aşamalarının başarısız olmasına sebep olmaktadır (Özmen, 2016: 22).



Şekil 8. Afet yönetim sistemi evreleri (Kadioğlu, 2008: 12).

Modern afet yönetim sisteminde hazırlık, zarar azaltma, erken uyarı sistemleri ve afet bilinci eğitimleri ile ilgili olan çalışmalara risk yönetimi denilirken afet sonrasında müdahale, etki analizi ve yeniden inşa gibi olan çalışmalara kriz yönetimi denilmektedir (Haddow ve Bullock, 2003: 1).

### 1.1.11. Afet Risk Yönetimi

Risk kavramı bir olayın sebep olabileceği kötü sonuçlar olarak tanımlanabilir. Riskten bahsedilebilmesi için belirli bir yerde bir tehlikenin veya büyük bir olayın meydana gelmesi, varlıkların bu olaydan zarar görmesi ve zarar görebilirlik oranının tahmin edilebilir olması gerekir. Risk yönetimi ise bölgelerin afetselliğinin belirlenmesi, oluşma sıklığının ve ihtimalinin değerlendirilmesi, afet oluşma tehdidinin azaltılması veya önlenmesi, riske maruz kalma ihtimali olan topluluklara zarar verme potansiyelinin hesaplanması ve tehdidi önleyici ya da azaltıcı kanunların ve politikaların

oluşturularak uygulamaya konulması gibi faaliyetleri ele almaktadır. Risk yönetimi amacı afet meydana gelmeden önce tehlikeleri ve riskleri belirleyerek bunlara karşı önlemler almaktır. Risk yönetimi aşamasında tüm tehlikeler ve riskler göz önünde bulundurularak afet planları oluşturulmalı, bölgesel olarak risk haritaları oluşturulmalı, afet anında kullanılacak envanterler hazırlanmalı, personellere ve topluma afet bilinci kazandırılmalı, müdahale personelleri eğitilmeli ve tatbikatlar yapılmalıdır (Özkul ve Karaman, 2007: 256).

Afet risk yönetiminin temel unsurları olarak hazırlık ve zarar azaltma evreleri karşımıza çıkmaktadır.

#### **1.1.11.1. Zarar Azaltama**

Bir tehlikenin olma olasılığını veya sonuçlarının toplumu daha az etkileyecek şekilde önlemler alınmasına zarar azaltma çalışmaları denilmektedir (Coppola, 2007: 22). Zarar azaltma bir afetin toplum üzerindeki etkilerini önlemler olarak en az zararla bu afetlerle baş edebilmeyi sağlamaktır. Zarar azaltma eylemlerini şu şekilde sıralamak mümkündür.

- Binaları afetlere dayanıklı hale getirmek,
- İmar planları yapmak,
- Yüksek binalarla ilgili yönetmelikler düzenlemek,
- Tehlikeli maddelerin kontrolü ile ilgili güvenlik önlemleri almak,
- Enerji hatlarını ve iletişim ağlarını güçlendirmek ve afetlere dayanıklı hale getirmek,
- Yapılan yeni otoyolların ve köprülerin afete eğilimli alanlardan uzağa inşa edilmesi veya alt yapıların ve yolların güçlendirilmesidir (Carter, 2008: 53).

#### **1.1.11.2. Hazırlık**

Hazırlık evresi zarar azaltma evresinde yapılan çalışmalar ve alınan önlemler ile afetlerin etkilerini tamamen ortadan kaldıramayacağından dolayı afetlere karşı her zaman hazırlıklı olunması gerektiği için ortaya çıkan bir evredir. Afete hazırlık aşaması meydana gelebilecek afetlerde can ve mal kaybını en aza indirmek, afet bölgesinde bulunan insanların güvenli yerlere tahliyesini sağlamak, zamanında arama kurtarma işlemlerine başlayarak devamlılığını sağlamak ve iyileştirme (yeniden inşa) döneminde yapılan çalışmaları kolaylaştırmak için yapılan eylemlerin tamamıdır (Özel, 2011: 18).

Bu evrede zarar azaltma aşamasında alınamayan önlemlerin olumsuz etkileri en aza indirilmeye çalışılmaktadır. Hazırlıklı olmak için toplumun her kesimi için risk ve kırılganlık analizleri yapılmalıdır. Bu analizlere dayalı olarak afet anında kullanılacak kaynak ya da envanterlerin belirlenmesi, lojistik, stoklama, tahliye, iletişim ve tüm ihtiyaçlar göz önüne alınarak planlar hazırlanmalıdır (Khorram-Manesh, 2017: 28).

Afetlere hazırlık çalışmaları sadece tek kurum ve kuruluşun yapması gereken bir süreç değil tüm paydaşların, toplumun ve kişilerin iş birliği içinde yapması gereken bir süreçtir.

Afet hazırlık çalışmaları şu şekilde özetlenebilir.

- Erken uyarı sistemleri kurmak ve bu sistemleri geliştirmek,
- Hazırlanan senaryolara göre tahliye planları yapmak,
- Afet anı için operasyon planları hazırlamak,
- Toplumun tüm kesimleri için afet bilinci eğitimlerinin düzenlemek,
- Toplumları afetlere dirençli hale getirmek,
- İlgili kurum ve kuruluşlarında dâhil olduğu tatbikatlar yapmak,
- Her il kendi planlarını hazırlamalı ve bu planları geliştirerek uygulamaya koymalıdır (Kadioğlu, 2011: 11).

### **1.1.12. Afet Kriz Yönetimi**

Kriz olağan operasyonları kesintiye uğratan veya durduran beklenmedik ya da kontrol altına alınması güç olan olaylardır. Kriz yönetimi kavramı ise kriz öncesi, sırası ve sonrasındaki yapılan faaliyetlerin ya da gösterilen çabaların tamamıdır. Kriz yönetiminden hükümet, devlet kurumları veya gönüllü kurum ve kuruluşlar kurtarma, zarar azaltma ve hazırlık yapmakla sorumludur (Unlu, Kapucu ve Sahin, 2010: 157).

#### **1.1.12.1. Müdahale**

Afet kriz yönetiminin olay meydana geldikten sonra devreye giren ilk aşamasıdır. Afet bölgelerine ve insanlara ilk müdahale ile başlayıp afetin seyrine göre kısa ya da uzun süreyle devam eden bir süreçtir. Acil müdahale veya afetlere müdahale olarak da adlandırılabilir (AFAD, 2014: 116).

Müdahale evresinin temel amaçları afet meydana geldiğinde afet bölgesine en hızlı sürede ulaşarak en fazla sayıda insan hayatı kurtarmak, arama kurtarma çalışmalarına zamanında başlamak, afet bölgelerinden tahliyeleri sağlamak ve meydana

gelen afeti en az hasarla ve kayıpla atlattırmasını sağlayarak afet öncesindeki normal yaşama bir an önce geçebilmeyi sağlamaktır (Ergünay, 1998; Özmen, 2018: 16).

### **1.1.12.2. İyileştirme**

İyileştirme evresi afet sonrasında kaybedilen ve hasara uğrayan değerlerin ya da varlıkların kazanılması veya onarılması için yapılan çalışmaların tamamıdır. Bu evre afet müdahale evresinden hemen sonra başlar ve durumun ciddiyetine göre bu çalışmalar aylarca veya yıllarca devam eder. İyileştirme çalışmaları kısa dönemde hayati ihtiyaçlar olan elektrik, su, kanalizasyon, yol ve altyapıların onarılması veya yenilenmesi ile uzun dönemde ise afet öncesi normal yaşama ya da daha gelişmiş hale getirilmesi için yapılan çalışmalardır (Çoban, 2019: 241).

İyileştirme aşamasında restorasyon, rehabilitasyon ve yeniden yapılanma faaliyetleri ile afetlerin etkileri ortadan kaldırılmaya çalışılır. Afet sonrası iyileştirme çalışmaları şunları içerir:

- Rutin yaşam hizmetlerinin en kısa sürede eski haline getirilmesi,
- Evsiz kalanlar için geçici barınma alanlarının oluşturulması,
- Onarılabilecek durumda olan binaların veya tesislerin güçlendirme çalışması yapılarak onarılmasının sağlanması,
- Afet etkilerinde zarar görmüş kişilere fiziksel ve psikolojik destek sağlanması,
- Afet tarafından tahrip edilen binaların veya alt yapıların yenilenmesi gibi faaliyetlerden oluşur (Carter, 2008: 57).

## **1.2. Deprem**

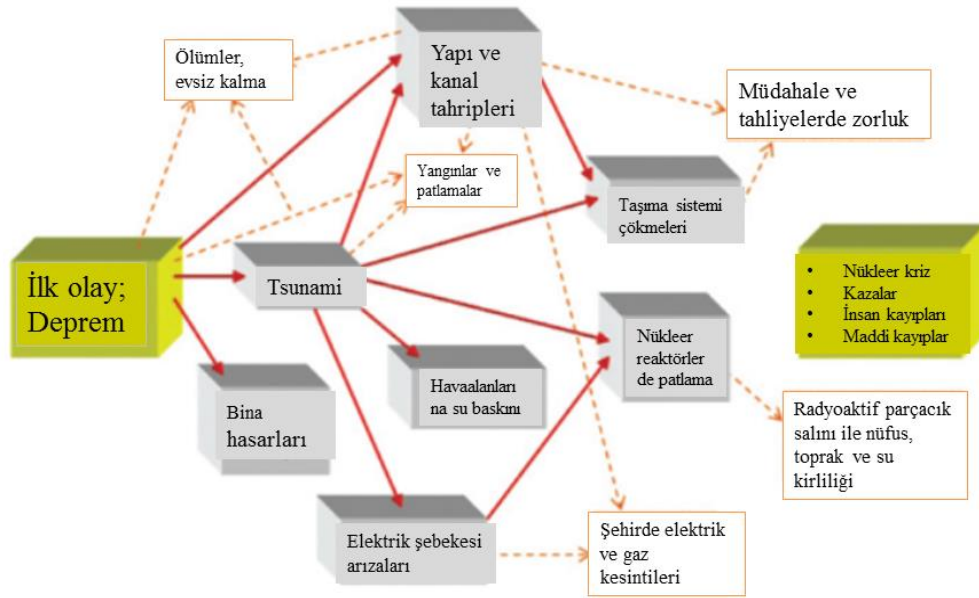
Bu başlık altında deprem ve deprem türleri, depremin şiddeti ve büyüklüğü, Türkiye'nin depremselliği, Türkiye'de meydana gelen büyük depremler, depremlerden sonra meydana gelen ikincil afetler, deprem sonrası meydana gelen yol hasarları ve bu hasarların tespiti incelenecektir.

### **1.2.1. Deprem ve Deprem Türleri**

Yerkabuğunda meydana gelen kırılmalar ya da yırtılmalar sonucunda ortaya çıkan titreşim dalgalarının yeryüzünde meydana getirdiği sarsıntı olaylarına deprem denir. Literatürdeki diğer deprem tanımlarına baktığımızda benzer tanımlamalarla karşılaşmaktadır. Bu tanımlamalar deprem türlerinden olan tektonik depremlerin tanımını kapsarken dünya genelinde yanardağı püskürmesi ve insan kaynaklı patlamalar

sonucunda yeryüzünde sarsıntılar oluşabildiği gibi çözünebilen kayaçların oluşturduğu mağara gibi boşluklardan dolayı çöküntü depremler meydana gelmektedir (Dölek, 2016: 324; Özmen, 2007a: 6).

Depremler meydana geldikleri bölgelerde binalara, alt yapılara, taşıma yollarına ve bölgede bulunan kritik tesislere zarar vererek bölgenin sosyal ve ekonomik yönden çökmesine neden olabilecek olaylar zincirine yol açabilir. Şekil 9’da da görüldüğü üzere bir deprem afetinin ardından olaylar domino etkisiyle arka arkaya meydana gelebilmektedir.



Şekil 9. Depremlerin etkileri (UKessays, 2018).

Depremleri türlerine göre tektonik depremler, çöküntü depremler, volkanik depremler ve insanların sebep olduğu depremler olarak dört kategoriye ayırabiliriz.

#### 1.2.1.1. Tektonik Depremler

Levha hareketleri sonucunda meydana gelen depremlere tektonik deprem denilmektedir. Bu depremler genellikle levha sınırlarında oluşurlar. Yeryüzünde oluşma sıklığı en fazla olan ve en fazla hasar meydana getiren depremlerin %90'nı bu grupta yer alırken Türkiye’de de en sık meydana gelen deprem türüdür (İşçi, 2008: 961).

### **1.2.1.2. Çöküntü Depremler**

Yer altında bulunan mağaralarda, kömür ve tuz ocakları gibi kolay eriyebilen kayaçların erimesi sonucunda oluşan boşlukların çökmesiyle meydana gelen depremlerdir. Bu depremler bölgesel olarak meydana geldiklerinden dolayı tektonik depremlere göre etkilediği alan ve hasar verme potansiyeli daha azdır. Çöküntü depremler sadece meydana geldikleri alanda can ve mal kaybına sebep olurlar (Özmen, 2007a: 9).

### **1.2.1.3. Volkanik Depremler**

Volkanik depremler yalnızca volkanik bölgelerde püskürmeden önce ya da püskürme sırasında yerin derin katmanlarında erimiş halde bulunan magmanın yeryüzüne çıkışı esnasında, fiziksel veya kimyasal olaylar sonucunda oluşan gazların sebep olduğu patlamalar ile oluşurlar. Genellikle yanardağı faaliyete geçmeden önce meydana geldiklerinden dolayı yanardağı patlamalarının habercisi niteliğindedirler. Bu depremlerde çöküntü depremler gibi bölgesel olarak oluşup meydana geldikleri alanlarda ekonomik ve sosyal kayıplara neden olmaktadır. Japonya ve İtalya'da meydana gelen depremlerin çoğu volkanik deprem grubuna girerken Türkiye'de aktif yanardağı bulunmadığı için bu depremlere rastlanılmamaktadır (Işın 2004: 7; Sür, 1993: 53).

### **1.2.1.4. İnsanların Neden Olduğu Depremler**

Nükleer patlamalar ve taşocağı patlamaları sonucu insan kaynaklı olarak meydana gelen olaylar sonucunda oluşan sarsıntılardır (Özmen, 2007a: 9).

## **1.2.2. Depremin Şiddeti ve Büyüklüğü**

Depremlerin etkisinin ve boyutunun ölçülmesinde büyüklük (magnitüd) ile şiddet kavramları karşımıza çıkmaktadır.

Magnitüd diğer adıyla büyüklük kavramı 1930 yılında Prof. C. Richter tarafından ileri sürülmüştür. Richter magnitüd kavramını deprem sırasında açığa çıkan enerjinin bir ölçüsü olarak tanımlamıştır. Sismografla kaydedilen deprem hareketlerinin en büyük genliğinin, periyod ölçüsünün ve alet kalibrasyon fonksiyonlarının kullanılması ile yapılan hesaplamalar sonucunda magnitüd değerleri elde edilmektedir. Günümüze kadar dünya genelinde meydana gelen depremler incelendiğinde en büyük magnitüde sahip depremler 31 Ocak 1906 Colombiya-Ekvator (8.9) ile 2 Mart 1933 Sanriko-Japonya

(8.9) depremi ve 22 Mayıs 1960 Şili (9.5) depremidir. Ülkemizde şimdiye kadar en büyük magnitüde sahip olan depremler ise 26 Aralık 1939 Erzincan (M 7.9), 17 Ağustos 1999 Kocaeli (M 7.4), 12 Kasım 1999 Düzce (M 7.2) ve 23 Ekim 2011 Van (M 7.2) depremleridir (Özmen, 2007b: 16). Depremler büyüklüklerine göre Tablo 4'teki gibi sınıflandırılmaktadır.

Tablo 4. Büyüklüklerine göre depremler ve magnitüdüleri (Özdemir, t.y.: 71).

<b>Magnitüd (M)</b>	<b>Büyüklük Derecesi</b>
<b><math>M &gt; 7</math></b>	Çok büyük depremler.
<b><math>5 \leq M \leq 7</math></b>	Orta büyük depremler
<b><math>3 \leq M \leq 5</math></b>	Küçük depremler
<b><math>1 \leq M \leq 3</math></b>	Mikro depremler
<b><math>1 &lt; M</math></b>	Ultra mikro depremler

Şiddet kavramı ise depremin yeryüzünde meydana getirdiği hasarlar ve etkiler olarak tanımlanabilir. Şiddetin ölçüsü insanların depremleri hissedip hissetmediği, deprem anında eşyaların devrilmesi ya da kırılması, binalarda meydana gelen hasar türlerine göre çeşitli etmenlere bakarak yapılır. Depremin şiddeti insanlara ve çevreye vermiş olduğu zararlar ölçülmektedir. Depremlerin şiddetini belirleyebilmek için uzun yıllar yapılan gözlemler ve bulgular ile şiddet cetvelleri oluşturulmuştur. Farklı şiddet cetvelleri ve şiddet tanımlamaları bulunmakla birlikte en yaygın kabul gören şiddet cetveli Mercalli Şiddet Cetvelidir. Romen rakamları ile gösteren bu cetvel on iki şiddet derecesinden oluşmaktadır. Bu cetvele göre I şiddetindeki bir deprem neredeyse hiç kimse tarafından hissedilmeyen küçük bir depremi gösterirken VII şiddetindeki bir deprem taş taş üstünde bırakmayan en yıkıcı deprem olarak gösterilmektedir (İşçi, 2008: 969).

Şiddet depremin insanlara ve çevreye vermiş olduğu hasarın bir ölçüyken büyüklük (magnitüd) bize depremin hissedilmesinden ya da meydana getirdiği hasarlar hakkında bilgi vermez, ancak depremi meydana getiren faydaki kırılmalar ya da kaymalar hakkında bilgi verir (Yeşilce ve Demirdağ, 2003: 52). Aşağıdaki tabloda (Tablo 5) ise şiddet ve büyüklük karşılaştırmalı olarak açıklanmıştır.


Tablo 5. Büyüklük ve şiddet karşılaştırması ( Baxter, 2000: 7).

Büyüklük	Şiddet	Açıklama
1.0 – 1.9	I	Neredeyse hiç hissedilmez.
2.0 – 2.9	II	Özellikle üst katlarda yaşayan insanlar hisseder.
3.0 – 3.9	III	İç mekânlarda üst katlarda fark edilir, ancak deprem olarak algılanmayabilir.
4.0 – 4.9	IV - V	IV. Birçok kişi tarafından hissedilir. Gece uyuyanları uyandırabilir. Binalara tır çarpmış hissi yaratır. Bulaşıklar, pencereler, kapılar ve asılı olan tablo ve saatlerden rahatsız edecek derecede ses çıkar. Duvarlardan çatlama sesi gelir. Açık alanda bulunan motorlu taşıtlar gözle görünür şekilde sallanır.
		V. Neredeyse herkes tarafından hissedilir. Gece uyuyan çoğu kişi uyanır. Korumasız alanda bulunan tabaklar ve pencereler kırılır. Etrafta bulunan sabit olmaya eşyalar devrilir. Sarkaçlı saatler durabilir.
5.0 – 5.9	VI - VII	VI. Herkes tarafından korkutucu derecede hissedilir. Bazı ağır mobilyalar devrilirler ya da yerlerinden oynarlar. Binalarda sıva çatlağı gibi hafif hasarlar meydana gelir.
		VII. İyi inşa edilmiş ve iyi tasarımı binalarda gözle görülemeyecek kadar az hasar oluşur, iyi inşa edilmiş sıradan yapılarda hafif ve orta hasar meydana gelirken kötü inşa edilmiş binalarda ağır hasar meydana gelir. Binalarda ki çoğu baca yıkılır.
6.0 – 6.9	VIII - IX	VIII. Özel tasarlanmış yapılarda hafif hasar, sıradan yapılarda önemli hasar ve kısmen çökmeler meydana gelirken; kötü inşa edilmiş yapılarda büyük hasarlar meydana gelir. Bacalar, sütunlar, anıtlar ve duvarlar düşer. Ağır mobilyalar devrilir.
		IX. Özel olarak tasarlanmış ve inşa edilmiş yapılarda önemli ölçüde hasar meydana gelirken diğer binalarda kısmi çökmeler ve temel kaymaları meydana gelir.
7.0 – 7.9	X - XI	X. Bazı iyi inşa edilmiş ahşap yapılarda yıkılmalar meydana gelirken; çoğu yığma ve betonarme yapılarda temelden yıkılmalar meydana gelir. Raylarda bükülmeler olur.
		XI. Köprüler yıkılır raylarda büyük ölçüde hasarlar meydana gelir. Birkaç yapı ayakta kalır.
8 +	XII	Yeryüzünde değişimler meydana gelir. Yer altında ve yer üstünde bulunan tüm yapılar yıkılır. Cisimler havaya fırlar. Ufuk kavramı kaybolur.

### 1.2.3. Türkiye'nin Depremselliği

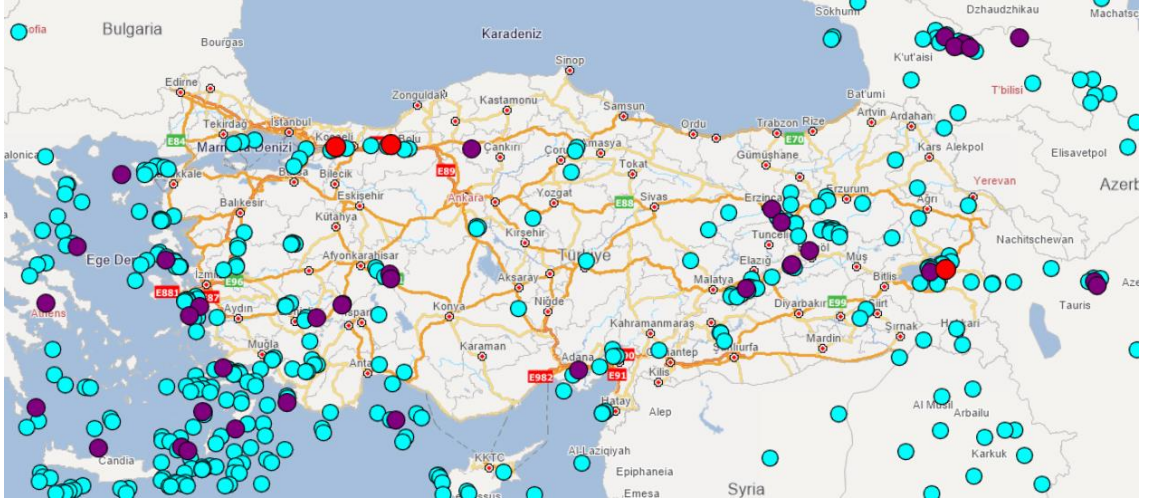
Ülkemiz en aktif deprem kuşağı olan Alp, Himalaya deprem kuşağında yer almaktadır. Türkiye'de yerleşim yerleri ve sanayi kuruluşlarının büyük bölümü kırılma ihtimali yüksek olan diri faylara yakın sahalara kurulmuşlardır. Bu diri fayların önemli özelliği hasar yapıcı depremler meydana getirmeleridir. Diri fayların yanı sıra Türkiye'de deprem zararlarının fazla olmasının diğer nedenleri ise yumuşak dolgu,

ova ve vadi gibi elverişsiz yerlere yoğun yapılaşma olmasından dolayıdır (Dölek, 2016: 325).



Şekil 10. Deprem tehlike haritası (URL-7, 2021).

Şekil 10'daki Türkiye haritasına göre ülkemiz deprem tehlikesi bakımından beş bölgeye ayrılmıştır. I. ve II. derece deprem bölgeleri büyük depremlerin meydana gelebileceği tehlikeli bölgelerdir. III. ve VI. derece deprem bölgelerinde meydana gelebilecek depremler daha küçük depremler iken I. ve II. derece deprem bölgesinde meydana gelen depremlerden etkilenecek olan yerlerdir. V. derece deprem bölgesi ise deprem tehlikesinin bulunmadığı alanlardır. Türkiye'nin yüzölçümünün %42'si I derece deprem bölgelerinde yer alırken %24'ü ise II. derece deprem bölgesinde yer almaktadır (Pampal, 2000).



Şekil 11. 1990 ile 2021 yılları arasında Türkiye'de M: 5 ve üzeri depremler (URL-8, 2021).

Şekil 11'deki haritada mavi ile gösterilen depremler magnitudü 5 ile 6 arasında olan depremler, mor ile gösterilen depremler magnitudü 6 ile 7 arasında olan depremler ve kırmızı ile gösterilen depremler ise magnitudü 7 den büyük olan depremlerdir. Son 31 yılda ülkemizde 7 ve üzeri büyüklüğünde üç tane deprem meydana gelmiş olup en sık meydana gelen depremler ise büyüklüğü beş ve beşten küçük olan depremlerdir.

#### 1.2.4. Depremlerden Sonra Ortaya Çıkan İkincil Afetler

Depremlerin sebep olduğu ikincil afetlerden yaygın olarak görülen afetler; heyelan, tsunami, zemin sıvılaşması ve yangınlardır. Büyük depremler sonucunda okyanus ve denizlerde oluşan dalgalar yerleşim yerlerine ulaşarak bölgeyi sular altında bırakabilmektedir. Heyelan, çığ ve toprak kaymaları da depremlerin tetikleme sonucunda meydana gelerek yerleşim yerlerini ya da yol ağlarında ağır hasarlara neden olmaktadır. Sıvılaşma ise ormansızlaşma, çevrenin yanlış kullanımı ve yanlış yere yapılaşma sonucunda depremlerden sonra ağır hasarlar meydana getiren ikincil afetler arasında yer almaktadır (Wisner, 2012: 292).

27 Aralık 1939 yılında Erzincan'da meydana gelen 7.9 büyüklüğündeki deprem sonucunda 32.968 insan hayatını kaybetmiş, 116.720 bina yıkılmıştır (Haçin, 2014: 40). Deprem sonrasında ise yollarda çığlar, heyelanlar ve köprülerde hasarlar meydana geldiğinden dolayı bölgeye yardım ulaştırılmasında sorunlar yaşanmıştır. Depremi kış aylarında meydana gelmesiyle beraber kullanılan sobalar yıkılan evlerde yangınların çıkmasına neden olmuştur (Gül, 2011: 137).

28 Mart 1970 yılında Gediz'de meydana gelen 7.2 büyüklüğündeki depremde 1.086 kişi hayatını kaybederken, 1.260 kişi ise yaralanmış ve 27.000 den fazla bina

hasara uğramıştır. Afet bölgesindeki hasarın fazla olmasının sebebi depremin kış aylarında meydana gelmesiyle evlerdeki sobaların devrilmesi sonucu yangınlar çıkmıştır. İtfaiye binasının çökmesi ile itfaiye araçlarının ve personellerinin enkaz altında kalmasından dolayı bölgedeki yangınlara müdahale edilememesi sonucunda çoğu kişi depremden dolayı değil depremden sonra meydana gelen yangınlar sonucu hayatını kaybetmiştir (Güner vd., 2019: 18).

17 Ağustos 1999 merkez üssü Gölcük olan 7.6 büyüklüğündeki depremde 18.373 kişi hayatını kaybederken, 23.781 kişi yaralanmış ve 505 kişi sakat kalmıştır (AFAD,2021). Deprem sonrasında İzmit bölgesinde tsunami meydana gelmiş olup bazı yerler sular altında kalmıştır. Yine deprem sonrasında TÜPRAŞ İzmit rafinesinde yangın meydana gelmiş ve yangın günlerce devam etmiştir (Danış ve Görgün, 2005: 1365; İlerisoy vd., 2022: 140).

23 Ekim 2011 yılında Van'da meydana gelen 7.2 büyüklüğündeki deprem sonucunda 644 kişi hayatını kaybetmiş, 1.966 kişi ise yaralanmıştır (URL-9, 2021). Bölgede ciddi hasara yol açan deprem sonucunda ulaşım sistemleri ve yapıları önemli derece etkileyen 77 tane heyelan meydana gelmiştir (İlerisoy vd., 2022: 141).

### **1.3. Yapay Zekâ**

Bu başlık altında

- Yapay zekâ kavramı,
- Yapay zekânın tarihçesi,
- Makine öğrenmesi,
- Derin öğrenme,
- Afet yönetimi alanında kullanılan yapay zekâ uygulamaları ele alınacaktır.

#### **1.3.1. Yapay Zekâ Kavramı**

Yapay zekâ kavramının literatürde çok farklı şekillerde tanımlamaları mevcuttur. Örneğin tek bir sözlükte yapay zekâ kavramının dört farklı tanımlaması bulunmaktadır. Bu tanımlar:

- Bilgisayar bilimi alanında yapay zekâ; öğrenme, akıl yürütme ve problemleri kendi kendine çözebilme gibi insanlar gibi düşünce süreçlerine girebilen bilgisayarların geliştirilmesi ile ilgilidir.
- Makinelerin insan zekâsı gibi öğrenme, uyum sağlama, kendi kendine düzetme gibi bazı işlemleri yapabilecek şekilde geliştirilebileceği,

- Geçmişte fiziksel gücün mekanik araçların kullanım yoluyla genişletildiği gibi insan zekâsının da bilgisayarın kullanılmasıyla genişletilmesi,
- Gelişmiş programlama teknikleriyle bilgisayarları daha etkin kullanma tekniklerinin incelemesi olarak tanımlanmaktadır (Kok vd., 2009: 271).

İnsanlara özgü olan anlama kabiliyetinin ve insan davranışlarının bilgisayar programları ile modellenmesidir. Yapay zekâ uygulamalarında makinelerin karmaşık problemler karşısında insan beyni gibi problemleri anlayabilme, çözümler üretebilme ve problemlere karşı deneyim kazanabilme gibi insan davranışlarının makinelere öğretilmesi amaçlanmaktadır (Yılmaz, 2017: 5).

Yapay zekânın bir diğer anlamı ise hiçbir canlı varlıklardan yararlanmadan tamamen insan eli ile yapılan, makinaların insanlara benzer şekilde hareket etmesi için ortaya çıkan teknolojidir (Aydın ve Değirmenci, 2018: 20).

Literatürde yapılan birçok farklı tanım mevcuttur ancak çoğu tanım aşağıdaki dört kategoride sınıflandırılabilir.

- İnsanlara benzer şekilde düşünen sistemler,
- İnsanlar gibi davranan sistemler,
- Rasyonel düşünebilen sistemler
- Rasyonel olarak hareket eden sistemler olarak tanımlamalar yer almaktadır (Kok vd., 2009: 271).

Literatürde yapay zekâ güçlü yapay zekâ ve zayıf yapay zekâ olarak iki farklı şekilde karşımıza çıkmaktadır.

#### **1.3.1.1. Güçlü Yapay Zekâ**

Güçlü yapay zekânın temel amacı makinelerin düşünmesini sağlamak veya insan zihnini temsil edilmesini sağlamaktır. Yakın gelecekte güçlü yapay zekâ sistemlerinin tamamen insanlar gibi çalışabilen ve insanların zekâ seviyesindeki makinelerin etrafımızda olacağı öngörülmektedir (Borana, 2016: 64).

#### **1.3.1.2. Zayıf Yapay Zekâ**

Zayıf yapay zekânın amacı makinelerin akıllıymış gibi hareket etmesinin sağlanabilmesidir. Zayıf yapay zekâ insanların hareketlerinin ve davranışlarının bilgisayarlara kolayca eklenebileceğini ve onları daha kullanışlı hale getirilebileceğini söyler. Örneğin, bir insan oyuncu bir bilgisayara karşı satranç oynadığında, insan oyuncu bilgisayar gerçekten etkileyici hamleler yapıyormuş gibi hissedebilir. Ancak

satranç uygulaması hiç düşünme ve planlama yapmamaktadır. Yaptığı tüm hamleler daha önce bir insan tarafından bilgisayara öğretilir ve bu sayede yazılımın doğru zamanda doğru hamleleri yapması sağlanır (Borana, 2016: 64).

Yapay zekânın kullanım alanlarına baktığımızda doğal dili anlama ve yanıt verme, bir dilden başka dile çeviri yapma, ekonomik, biyolojik problemlerin çözülmesi için modeller oluşturma, keşifler için robotik sistemlerin oluşturulması, güvenlik, ulaşım, endüstriyel otomasyon, askeriye, güvenlik ve eğlence gibi çok farklı alanlarda kullanılmaktadır (Pannu, 2015: 80).

### **1.3.2. Yapay Zekânın Kısaca Tarihi Gelişimi**

1920’li yıllara kadar yapay zekâ sadece bir bilim kurgu iken 1950’lerde insan zekâsının doğasına yönelik yapılan bir araştırma olarak başlamıştır. Alan Turing Computing Machinery and Intelligence (Bilgisayar Makineleri ve Zekâ) başlıklı bir makale yayınlayarak Taklit Oyunu (Turing Testi) tanıtmıştır. Bu test ile bir insana ve bir bilgisayara sorular sorularak hangisinin bilgisayar hangisinin insan olduğu ayırt edilemezse makine bu testi başarıyla geçerek zekâsını kanıtlamaktaydı. Yapay zekâ kavramı ise bilimsel bir terim olarak Marvin Minsky, John McCarthy, Shannon ve Nathan Rochester tarafından düzenlenen Dartmouth Konferansı’nda ortaya çıkmıştır (Ergen, 2019: 6).

Yapay zekânın tarihçesi kısaca tarih öncesi dönem, dartmouth konferansı, karanlık dönem, Rönesans dönemi ve ortaklık dönemi olmak üzere beş dönemden oluşmaktadır.

#### **1.3.2.1. Tarih Öncesi Dönem**

Tarih öncesi dönemde Yunan mitolojisinde rüzgârın yaratıcı adıyla bilinen Daedelu’sun yapay insan oluşturmaya çalışması ilk örneklerinden olarak gösterilmektedir. 1884 yılında Charles Babbage isimli bilim insanı makinelerin bazı zeki davranışları sergileyebilmesi için deneyler yapmıştır. 1950’li yıllarında ise Shannon isimli bilim insanı bilgisayarların satranç oynayabileceği iddiasında bulunmuştur. Bu dönem 1960’lı yılların başlarına kadar sürdürülmüştür.

#### **1.3.2.2. Dartmouth Konferansı**

Bu konferans ile yapay zekâ alanında yeni bir dönem başlamış olup yapay zekâ kavramından ilk defa bahsedilmiştir.

### 1.3.2.3. Karanlık Dönem (1965-1970)

Bu dönemin karanlık dönem olarak adlandırılmasının nedeni çok az gelişim sağlanabilmesinden dolayıdır. Bilgisayar uzmanları ve filozoflar bu dönemde verileri yükleyerek akıllı bilgisayarlar yapmaya çalışmışlardır.

### 1.3.2.4. Rönesans Dönemi (1970-1975)

Hastalık teşhisi gibi birçok yeni çalışmaların yapıldığı yapay zekânın bu gün ki temelleri atıldığı dönemdir.

### 1.3.2.5. Ortaklık Dönemi (1975-1980)

Bu dönemde yapay zekâ ile uğraşan uzmanlar psikoloji ve dil bilimcilerinin de yapay zekâ uygulamalarında yararlına bilineceği anlaşılmıştır (Bozüyük vd., 2005: 8). Yapay zekânın kronolojik olarak tarihçesi Tablo 6'da anlatılmaktadır.

Tablo 6. Yapay zekâ tarihinin kronolojisi (Yılmaz, 2017: 18).

<b>MS 1.yy</b>	Antik çağda yaşayan İskenderiyeli Heron su ve buhar gücüyle çalışan otomatik sistemler yapmıştır.
<b>1206</b>	Sibernetik biliminin öncülerinden Ebu'l İz Bin Rezzaz El Cezeri, su ile çalışan otomatik kontrollü makineler yapmıştır.
<b>1623</b>	Dört işlemi yapabilen hesap makinesi Wilhelm Schickard tarafından icat edilmiştir.
<b>1672</b>	Günümüzdeki bilgisayarların temelini oluşturan ikili sayma sistemi Gottfried Leibniz tarafından geliştirilmiştir.
<b>1822-1859</b>	Charles Babbage mekanik olarak çalışan hesap makinesini tasarlamıştır. Ada Lovelace ise Babbage'in yapmış olduğu makineler üzerine delikli kartlarla hazırlamış olduğu çalışmalardan dolayı ilk bilgisayar programcısı olarak anılmaktadır.
<b>1923</b>	Karel Capek, Rossum'un Evrensel Robotları adlı tiyatro oyunu ile ilk kez robot kavramından bahsedilmiştir.
<b>1931</b>	Eksiklik teoremi kendi ismiyle Kurt Gödel tarafından ortaya atılmıştır.
<b>1936</b>	Z1 adlı 64K hafıza kapasitesine sahip programlanabilme özelliği olan bilgisayar Konrad Zuse tarafından geliştirilmiştir.
<b>1956</b>	Matematik problemlerinin çözülmesini yarayan Mantık Teorisi (Logic Theorist LT) isimli program Newell, Shaw ve Simon tarafından ortaya atılarak kabul edilen ilk yapay zekâ sistemidir.
<b>1950'lerin sonu-1960'ların başı</b>	Makine çevirisi için sematik ağlar Masterman ve arkadaşları tarafından geliştirilmiştir.

Tablo 6. (Devamı)

<b>1958</b>	MIT'den Mc Carty, LISP (list processing language) dilini oluşturmuştur.
<b>1960</b>	İnsanlar ve makineler arasındaki ilişkiyi Licklider yapmış olduğu çalışmada anlatmıştır.
<b>1962</b>	Endüstri alanında ilk defa robot üreten firma olan Unimation kurulmuştur.
<b>1965</b>	Yapay zekâ programı olan ELIZA yazılmıştır.
<b>1966</b>	Stanford Üniversitesinde ilk hareketli robot olan "Shakey" üretilmiştir.
<b>1974</b>	Cerf ve Kahn tarafından çalışmalarında ilk defa internet terimi kullanılmıştır.
<b>1978</b>	Yapay zekâ alanında önemli çalışmaları olan Simon sınırlı Rasyonalite Teorisi adlı çalışması ile Nobel ödülü kazanmıştır.
<b>1979</b>	Standfor Arabasının testi başarıyla gerçekleştirilmiştir.
<b>1981</b>	IMB adlı ilk kişisel bilgisayar üretilmiştir.
<b>1993</b>	Cog adlı ilk insan görünümlü robot üretilmeye başlanmıştır.
<b>1997</b>	Dünyaca ünlü satranç oyuncusu olan Kasparov, Deep Blue adlı bilgisayara yenilmiştir.
<b>1998</b>	Furby isimli ilk yapay zekâ oyuncağı piyasaya sürülmüştür.
<b>2000</b>	Kısmet adlı iletişimde jest ve mimiklerini kullanabilen robot tanıtılmıştır.
<b>2005</b>	Asimo isimli insan kabiliyetine ve becerisine ne yakın olan yapay zekâyâ sahip robot tanıtılmıştır.
<b>2010</b>	Asimo'nun zihin gücü kullanarak harekete geçmesi sağlanmıştır.

### 1.3.3. Yapay Zekâ Teknikleri (Uygulamaları)

Literatürde yapılan çalışmalara baktığımızda yapay zekâ alanında kullanılan çok fazla teknik bulunmaktadır. Bu başlık altında en fazla kullanılan ve en çok karşılaştığımız yapay zekâ teknikleri incelenecektir.

#### 1.3.3.1. Uzman Sistemler

Felsefi sistemlere benzer şekilde uzman düşüncelerini taklit ederek ve veri tabanları ile çalışarak önemli problemleri çözmek için kullanılmaktadırlar. Problem çözmeye odaklı bilgi tabanlı sistemlerdir (Tuzcuoğlu, 2003: 77). Uzman sistemler bir problem karşısında problemleri uzman kişiler gibi bilgi ve mantık çerçevesinde çözüme kavuşturabilen sistemlerdir. Uzman sistemlerin amaçları kurulan modellemeler ile problemler karşısında uzmanlar gibi mantık çerçevesinde çözülmesini sağlamaktır. Bu sistemler ile insan beyninin muhakeme süresi makineler ile azaltılmaktadır. Bilgi kazanma, özet sonuçlar üretme, sistem performansı değerlendirme, hata ayıklama ve

deneme testlerinin yapılması gibi alanlarda bu algoritmalar kullanılmaktadır (Atalay ve Çelik, 2017: 159).

### **1.3.3.2. Genetik Algoritmalar**

Holland tarafından biyolojik evrim sürecinden esinlenerek genetik algoritmalar önerilmiştir (Coşkun, 2007: 144). Genetik algoritmalarda problemlere çözümler üretmek için kromozoma benzer veri yapıları sayesinde genetik işlemler ile yeni çözümler ortaya konulmaktadır. Genetik biliminde canlılarla ilgili önemli bilgiler kromozomlar tarafından saklanırken genetik algoritmalarda ise çözülmesi istene problemler ilgili bağımsız değişkenler problemin önemli bilgilerini oluşturur (Civalek, 2005: 1329). Genetik algoritmalar rotalama, optimizasyon, görüntü işleme, çizelgeleme, hat dengeleme ve iyileşme yöntemleri alanlarında kullanılmaktadır (Yılmaz, 2017: 21).

### **1.3.3.3. Bulanık Mantık**


Günlük yaşamımızda sonuçları kesin olarak bilinmeyen onlarca durumla karşı karşıya kalırız. İnsanların düşünce biçimine benzer şekilde çalışır. Kümeleme mantığında çalışırsak bir üyenin bir kümede olup olmadığını üyelik fonksiyonları ile belirlemeye çalışır (Tektaş vd., 2002: 3). Bulanık mantıkla belirsizlik durumlarına cevap verilmek amaçlanmaktadır. Bulanık mantığın avantajları şu şekilde sıralanabilir:

- Karmaşık problemler karşısında basit çözümler üretebilmeyi amaçlar.
- Klasik mantıkla karmaşık problemleri çözüme kavuşturmak oldukça maliyetli bir işken, bulanık mantık sayesinde bu maliyet düşürebilir ve problemlerin daha iyi analizi sağlanır.
- Üyelik fonksiyonları sayesinde küçük yazılımlar kullanılarak problemler çözüme kavuşturulur.
- Bulanık mantık özellikleri yeraltı treni (metro), bulaşık makinesi, çamaşır makinesi, elektrikli süpürge ve sanayi alanlarında oldukça sık kullanılmaktadır (Yılmaz, 2017: 21).

### **1.3.3.4. Yapay Sinir Ağları**

İnsan beyninden ya da merkezi sinir sisteminden esinlenerek oluşturulan bilgi tabanlı bir sistemdir. Yapay sinir ağları ile ilgili ilk çalışmalar beyni oluşturan nöronların bilgisayarlara uyarlanması ile başlamıştır (Arı ve Berber, 2017: 56).

Şekil 12’de de görüldüğü üzere yapay sinir ağları ile biyolojik sinir hücrelerinin çalışma prensibi benzer şekildedir. Örneğin biyolojik sinir hücreleri snapslar ile iletişim kurarken yapay sinir ağları ise bilgileri toplama fonksiyonu ile toplarlar. Biyolojik sinir hücreleri gelen bilgileri axon’lar ile diğer hücelere gönderirken yapay sinir ağları aktivasyon fonksiyonları sayesinde çıktı üreterek diğer hücelere gönderirler. Yapay sinir ağlarının mimarisi girdi katmanı, ara katmanlar ve çıktı katmanı olmak üzere üç bölümden oluşmaktadır (Öztemel, 2003: 16).



Şekil 12. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo’dan aktaran Öztürk ve Şahin, 2018: 28).

Yapay sinir ağlarının kullanım alanları olarak, üretim planlaması, kanser teşhisi ve tedavisi, parmak izi tanıma, kredi kartı dolandırıcıların tespiti, ses tanıma, el yazısı tanıma, savunma sanayisinde hedef seçme, bankacılık da müşteri analizi ve kredi değerlendirilmesi, uçuş simülasyonları gibi birçok örnek verilebilir (Keskenler ve Keskenler, 2017: 11; Yılmaz, 2017: 19).

#### 1.3.4. Makine Öğrenmesi

Yapay zekâ tekniklerinden olan makine öğrenmesi insan ve biyolojik bilgi işleme görevlerini taklit edebilen veriye dayalı yöntemlerdir. Makine öğrenme modelleri ilk başlarda insan biyolojisinden ilham alan modeller etrafında toplanmış olsa da günümüzde bilgiyi işleyebilen, matematiksel modellemeler ve tahmin modellemeleri yapabilen bilgisayar biliminde ve bilgi işleme alanlarında kullanılmaktadır (Barber, 2012: 305).

Problemleri çözüme kavuşturmak için problemlere ait veri setleriyle oluşturulan algoritmalara makine öğrenmesi denilmektedir. Bu modellerde mevcut veri setiyle ya da kullanılan algoritmalarla en yüksek performans elde edilmek üzere oluşturulmaktadır. Bu sebeple kümeleme, tahmin ve sınıflandırma yapabilme özelliklerine sahip k-en yakın komşu algoritması, karar ağaçları, lojistik regresyon destek vektör makineleri gibi makine öğrenme yöntemleri geliştirilmiştir (Atalay ve Çelik, 2017: 161).

Makine öğrenme stratejileri denetimli, denetimsiz ve takviyeli öğrenme olmak üzere üç başlık altında incelenebilir.

#### **1.3.4.1. Denetimli Öğrenme (Supervised Learning)**

Modeller önceden eğitilmiş veri setleriyle eğitilerek kurulmaktadır. Denetimli öğrenmeyi kullanan sinir ağları eğitim verilerini doğru bir şekilde sınıflandırmak için ağlardaki bağlantıların ağırlıklarını değiştirerek öğrenir. Bu sayede sinir ağları eğitim verilerini kullanarak doğru tahminde bulunabilir. Denetimli öğrenme bir modelin etiketli bir veri kümesinden eğitildiği hem giriş hem de çıkış parametrelerine sahip bir makine öğrenme türüdür (Coppin, 2004: 285).

#### **1.3.4.2. Denetimsiz Öğrenme (Unsupervised Learning)**

Denetimsiz öğrenmede makine yalnızca giriş verilerini kullandığı çıkış verilerini kullanmadığı öğrenme biçimidir. Modele herhangi bir bilgi vermeden etiketsiz verilerden algoritmalar kendi kendine doğal yapının öğrenmesi sağlanır. Model karar verme, gelecekteki girdileri tahmin etme ve girdileri başka bir modele verimli bir şekilde iletme vb. için kullanılabilir. Kümeleme örnekleri denetimsiz öğrenmenin örneğidir (Ghahramani, 2003: 73).

#### **1.3.4.3. Takviyeli Öğrenme (Reinforcement Learning)**

Modelin öğrenme aşamasında en uygun çözüm model tarafından bilinmektedir. Bundan dolayı problemin çözümleri tekrarlanacak şekilde belirlenmelidir. Sistem tarafından mantıklı yaklaşımlara ödüller verilir yanlış yaklaşımlara ise cezalandırılır. Bu sayede sistem karışık çevresel etmenleri hesaba katarak tepki üreterek kendi çözümlerini bulmaktadır (Aylak vd., 2021: 78).

Makine öğrenme uygulamalarının bilgisayarla görme, tahmin, anlamsal analiz, doğal dil işleme ve bilgi alma gibi çeşitli alt dalları bulunmaktadır.

- Bilgisayarla görme, nesne tanıma ve nesne algılama işlemleri yapılır.

- Tahmin, metin sınıflandırma, görüntü analizi, tıbbi teşhis, siber saldırı tespiti ve müşteri sadakat tespiti gibi uygulamalarda kullanılır.
- Semantik analiz ve doğal dil işleme ve bilgi erişimi, semantik analiz, paragraflardan, cümlelerden, kelimelerden oluşan söz dizimleri yapılarının bir bütün olarak yazı düzeyiyle ilişkilendirilmesi sürecidir. Doğal dil işleme, bilgisayarların doğal dil verilerini doğru şekilde işlemesi için nasıl programlanacağıdır. Bilgi alma, bir belgedeki bilgileri arama, belgedeki verileri, ses ve görüntü veri tabanlarını tanımlayan üst verileri aramak için kullanılmıştır (Shinde ve Shah, 2018: 2).

Günümüzde makine öğrenmesi yöntemlerinin: kanser tespiti ve tanısında, eposta bildirimlerinde kötü amaçlı yazılımların filtrelenmesinde, kendi kendine giden otonom araçlarda, sanal kişisel asistanlarda (örneğin siri), ses ve görüntü tanıma gibi oldukça yaygın kullanım alanları bulunmaktadır (Shinde ve Shah, 2018: 3). Şekil 13'te makine öğrenmesinin kullanım alanlarının bazılarını örnekler verilmiştir.



Şekil 13. Makine öğrenmesinin kullanıldığı bazı uygulamalar (URL-10, 2021).

### 1.3.5. Derin Öğrenme

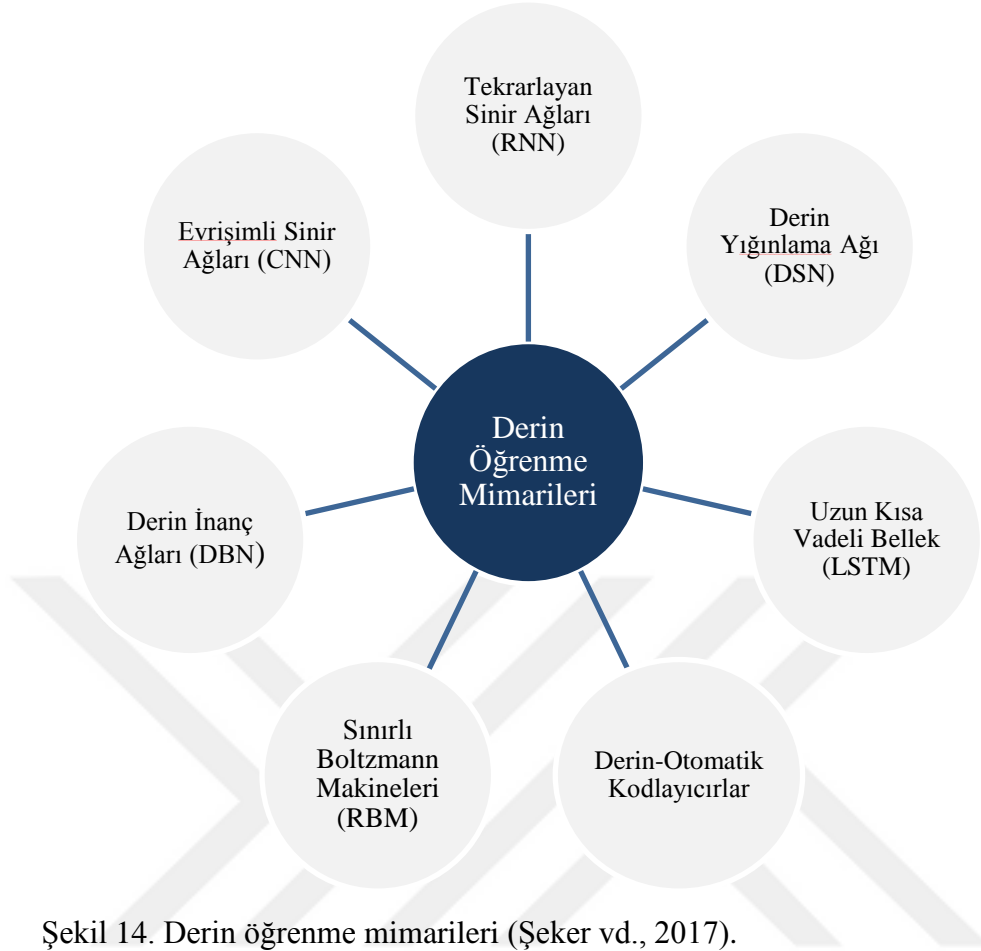
Derin öğrenme bilgisayarların görüntü ve ses tanıma gibi algısal sorunları çözmeye yarayan güçlü bir makine öğrenme yöntemidir. Derin öğrenme yöntemleri

yapay sinir ağı gibi büyük veri kümelerindeki yapıyı öğrenmek için fazla sayıda işleme katmanı kullanır. Her katmanda verilerden yeni kavramlar öğrenmektedir. Örneğin görüntü yorumlama yapan bir derin sinir ağı ilk katmanda basit kenarları tanımayı öğrenirken sonraki katmanlarda bu kenarlardan oluşan karmaşık yapıları ve şekilleri öğrenecektir (Rusk, 2016: 35).

1980'lerin sonlarından bu yana makine öğrenmesi gelişiminde iki yeni alan olan sığ öğrenme ve derin öğrenme alanları ortaya çıkmıştır. 1980'lerin sonlarında, yapay sinir ağı için geri yayılım algoritmasının icadı, istatistiksel modellere dayalı bir makine öğrenimi yöntemini başlatmıştır. Geri yayılım algoritmasının kullanılmasıyla bir yapay sinir ağı modelinin birçok eğitim verisinden kalıpları öğrenmesine ve bu kalıplara dayalı tahminler yapması sağlanmıştır. Bu yöntemle önceki sistemlere göre birçok yönden başarılar elde edilmiştir. 1990'larda ise destek vektör makineleri (SVM) ve Lojistik Regresyon (LR) gibi çeşitli sığ makine öğrenme modelleri önerilmiştir. Bu modeller hem teorik hem de uygulama alanlarında üstün başarılar elde etmiştir. 2000 yılından bu yana, İnternet'in hızlı gelişimi, büyük miktarda verinin akıllı analizi ve tahmini için bu alana yoğun ilgi duyulmuştur. Derin öğrenme ise 2006 yılında Geoffrey Hinton tarafından yayınlanan bir makale ile gelişmeye başlamıştır. 2011 yılında Microsoft ve Google derin sinir ağlarını kullanarak konuşma tanıma üzerine bir çalışma yapmışlar ve diğer yapılan çalışmalara göre hata oranını %20 ila %30 arasında azaltmayı başarmışlardır. 2012 yılında ise derin sinir ağı ile görüntü tanıma çalışması ile mükemmel sonuçlar elde edilmiştir. Derin öğrenme algoritmaları girdileri birkaç gizli katman aracılığıyla dönüştürdüğü ve çıktılarını ise gizli katmalardaki hesaplamalardan türetildiği derin sinir ağı modellerinden oluşmaktadır. Örneğin, bir görüntü verildiğinde, derin bir sinir ağı, her gizli katmanda bu görüntünün farklı özelliklerini çıkarabilir. Girdi olarak bir görüntünün pikselleri verildiğinde, kenarlar, komşu piksellerin renkleri veya parlaklığı karşılaştırılarak birinci katmanda tanımlanabilir. Ardından, ikinci gizli katman, kenarların tanımını kullanarak köşeleri ve konturları algılayabilir. Bundan sonra, belirli nesnelere parçaları, belirli kontur ve köşe koleksiyonları aranarak bulunabilir. Son olarak, giriş görüntüsündeki nesnelere tanımlanabilir. Günümüzde derin öğrenme uygulamaları endüstri, akademi, tıp, robotik gibi birçok farklı alanda kullanılmaktadır (Hao vd., 2016: 418).


#### **1.3.5.1. Derin Öğrenme Mimarileri**

Şekil 14'te kullanılan bazı derin öğrenme mimarileri gösterilmiştir.



### 1.3.5.1.1. Tekrarlayan Sinir Ağları (RNN)

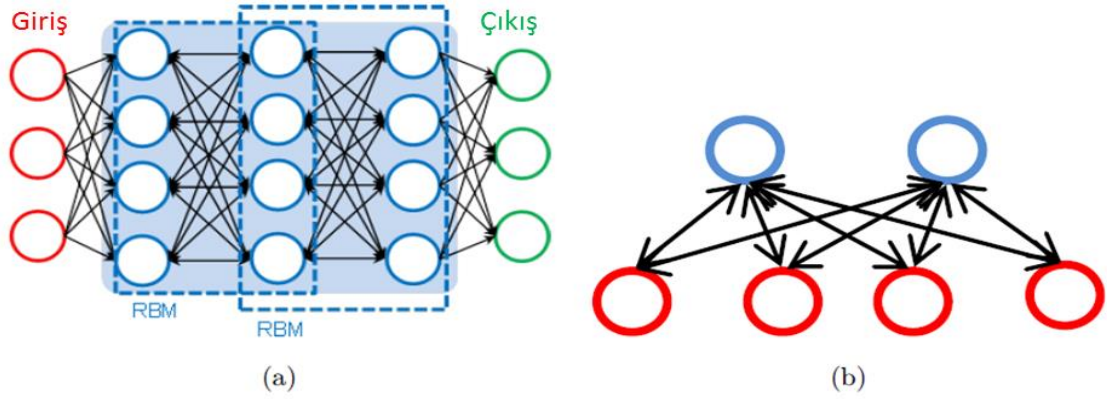
Konuşma ve dil gibi sıralı girdileri içeren alanlarda kullanılmaktadır. RNN'ler giriş katmanındaki bilgileri diğer gizli katmanlara ileterek geri yayılım algoritmaları ile dizinin tüm geçmişi hakkında bilgi sahibi olur. Örneğin RNN'ler ile bir konuşma dilinde arka arkaya gelen kelimeler ile bir sonraki kelimelerin tahmini yapılabilmektedir (LeCun vd., 2015: 441).



Şekil 15. Tekrarlayan sinir ağı mimarisi (Hao vd., 2016: 423).

### 1.3.5.1.2. Derin İnanç Ağları ve Sınırlı Boltzmann Makineleri

Derin inanç ağları (DBN'ler) fikri 2006 yılında Geoffrey Hinton tarafından önerilmiştir. Çok katmanlı nöronlardan oluşan DBN'ler veri tanıma veri üretme ve sınıflandırma işlemlerinde kullanılırlar. Bu nöronlar görünür birimler ve gizli birimler olarak iki guruba ayrılırlar. Görünür birimlerle bilgi alma işlemi yapılırken gizli birimlerle öznelik çıkarımları yapılmaktadır. Bir derin inanç ağı birden fazla sınırlı bozmaalt makinelerinden oluşur. RBM, ilk olarak Smolensky tarafından bir kavram olarak önerilmiş ve Hinton'un 2006' da yapmış olduğu çalışmasını yayınlamasından bu yana öne çıkmıştır. RBM'ler, girdilerine göre olasılık dağılımını öğrenebilen yapay sinir ağlarının değişken modellerini oluşturmak için kullanılmaktadır ( Hao vd., 2016: 425; Liu vd., 2017: 3).



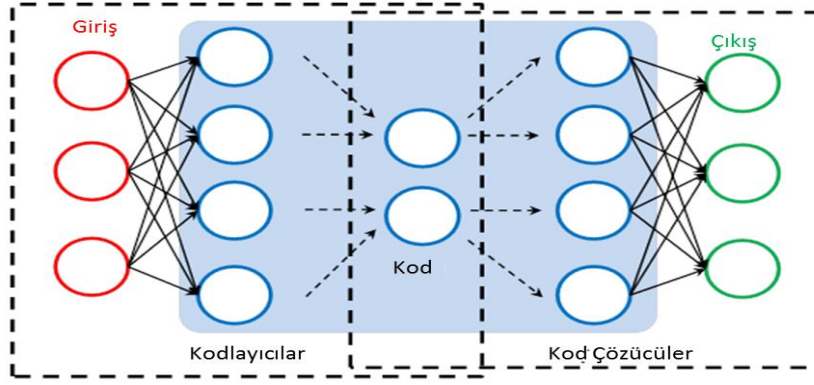
Şekil 16. (a) Derin inanç ağı. (b) Sınırlı boltzmann makinesi (Hao vd., 2016).

### 1.3.5.1.3. Uzun Kısa Vadeli Bellek (LSTM)

Tekrarlayan sinir ağlarının bir uygulaması olan LSTM'ler ilk olarak 1997 yılında Hochreiter tarafından önerilmiştir. LSTM'ler ileri beslemeli mimarilerden farklı olarak önceki durumların bilgisini koruyarak bellek ve durum farkındalığı gerektiren işlerde kullanılabilir. Günümüzde Google, Apple ve Amazon tarafından ses tanıma uygulamalarında kullanılmaktadır (Shrestha ve Mahmood, 2019: 53048).

### 1.3.5.1.4. Derin-Otomatik Kodlayıcılar

Derin sinir ağları içinse yaygın olarak kullanılan denetimsiz öğrenme algoritmalarıdır. Otomatik kodlayıcılar veri kümelerinin boyutunu küçülterek aynı öğrenme kapasitesine ulaşmayı amaçlar. Bu algoritma ile verilerdeki en önemli özellikler öğrenilerek veri boyutu küçültülmüş olur (Hao vd., 2016: 430).

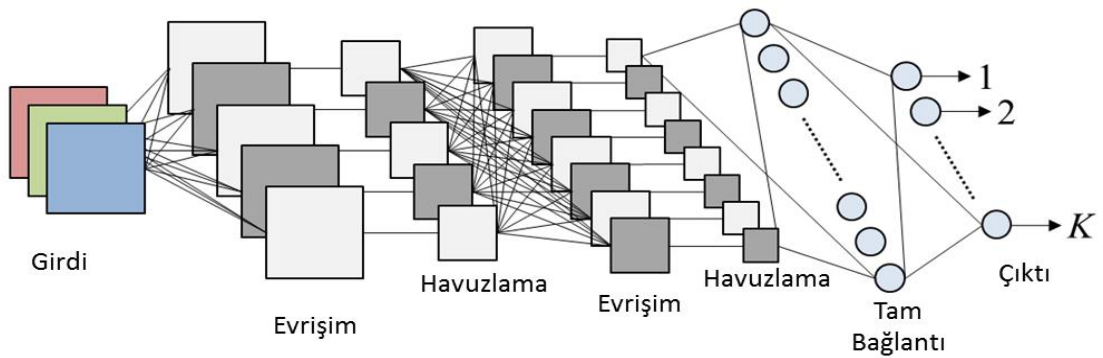


Şekil 17. Otomatik kodlayıcı mimarisi (Hao vd., 2016: 430).

### 1.3.5.1.5. Evrişimli Sinir Ağları (CNN)

Evrişimli sinir ağları görüntü işleme ve görüntü sınıflandırma için kullanılan son derece başarılı olan derin öğrenme mimarilerindedir. İlk olarak 1998 yılında LeCun ve arkadaşları tarafından hazırlanan Belge Tanımaya Uygulanan Gradyan Tabanlı Öğrenme adlı makalede önerilmiştir (LeCun vd., 1998). Krizhevsky ve arkadaşları 2012 yılında 1.2 milyon görüntü kullanarak eğittikleri model ile ILSVRC-2012 yarışmasını kazanarak evrişimli sinir ağlarının başarısı gözler önüne serilerek derin öğrenmenin yeni çağı başlamıştır (Krizhevsky vd., 2012).

Evrişimli sinir ağı (CNN) biyolojik sinir ağlarından ilham alınan katmanlarının en az bir tanesinde evrişim kullanılan bir tür ileri beslemeli yapay sinir ağıdır. Evrişimli sinir ağları özellikle resimleri ve videolar gibi iki boyutlu verileri tanımak için tasarlanmıştır. Görüntüler doğrudan ağın giriş katmanında kullanılabilir, bu sayede geleneksel görüntü tanıma algoritmalarındaki karmaşık özellik çıkarma ve veriyi yeniden oluşturma süreci ortadan kaldırılmış olur (Hao vd., 2016: 420).



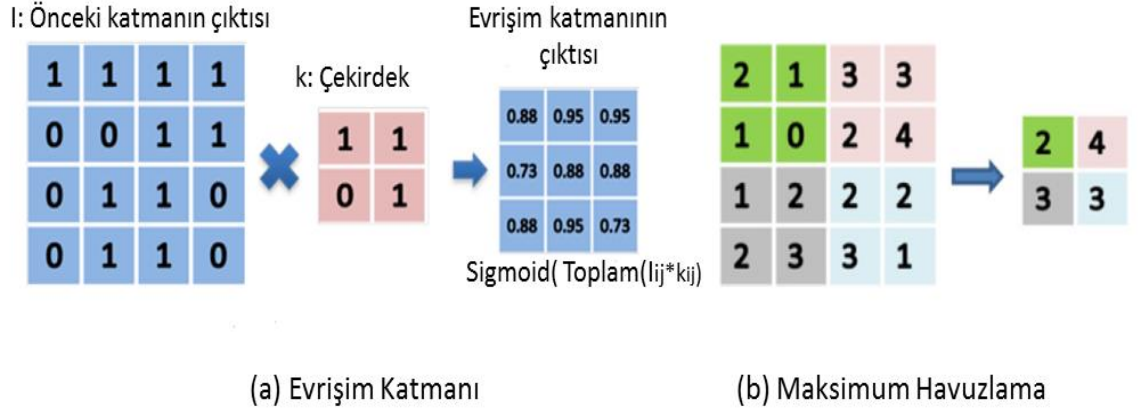
Şekil 18. Evrişimli sinir ağının kavramsal yapısı (Hidaka ve Kurita, 2017: 161).

Evrişimli sinir ağlarının giriş görüntüleri genellikle RGB ( Kırmızı, Yeşil, Mavi) üç kanaldan ya da gri tonlama olarak tek kanaldan oluşmaktadır. Şekil 18’de de gösterildiği üzere evrişimli sinir ağları giriş katmanı, birkaç tane evrişim veya havuzlama katmanı, sınıflandırma problemleri için bir ya da birden fazla tam bağlantı katmanından ve çıktı katmanından oluşur (Hidaka ve Kurita, 2017: 160).

Evrişimli sinir ağları görüntü işleme, görüntü sınıflandırma, görüntü bölütleme, nesne algılama, yüz tanıma ve konuşma işleme gibi birçok alanda kullanılan özel bir yapay sinir ağı türüdür. Evrişimli sinir ağları görüntü ve video gibi renkli görüntüleri içeren verileri işlemek için tasarlanmıştır. Görüntülerden bilgi çıkarmak için evrişim filtresini kullanırlar. Sırasıyla katmanlarda görsellerin kenarlarını algılama, nesnelerin bir kısmını algılama ve son katmanda ise yüz ya da geometrik şekil gibi karmaşık yapılar algılanabilir. Evrişimli sinir ağları görsel işlemede evrişim katmanı, havuz katmanı ve tam bağlantılı katmanı olmak üzere üç ana katmandan oluşmaktadır (Bezdán ve Bacanin, 2019: 446).

#### **1.3.5.1.5.1. Evrişim (Convolution) Katmanı**

Giriş verilerin özelliklerini geliştirir ve karmaşıklığı azaltır. Evrişim katmanının girdisi önceki katmanın çıktısıdır. Her girdi için hücrelerin içinde ağırlık olan bir çekirdek vardır. Bir evrişim katmanının içindeki çekirdekler aynı boyuta sahiptir. Şekil 19 (a)'da gösterildiği gibi, çekirdek boyutu  $2 \times 2$ 'dir ve bu evrişim katmanının girişi  $4 \times 4$ 'tür. Çekirdeği adım = 1 ile girişin sol üst köşesinden sağ alt köşesine taşıyarak  $(4 - 2 + 1) \times (4 - 2 + 1) = 9$  boyutunda bir çıktı elde edilir. Bu çıktıdaki her sayı iki adımda hesaplanır. İlk adım, çekirdeğin kapsadığı ağırlıklı sayıların toplamını hesaplamaktır. İkinci adım ise ilk adımın sonucunu 0 ile 1 arasında bir kesire sıkıştıran bir sigmoid fonksiyonudur (Hao vd., 2016: 421).




Şekil 19. Evrişimsel bir sinir ağının farklı katmanları (Hao vd., 2016: 421).

### 1.3.5.1.5.2. Havuzlama (Pooling) Katmanı

Giriş verilerinden bir alt örnek alır. Havuzlama katmanı, girdiyi birkaç küçük bölgeye böler ve her bölge için ortalama ya da maksimum gibi bazı işlevleri yerine getirir. Maksimum bir havuzlama katmanı Şekil 19 (b)'de gösterilmektedir. 4×4 boyutundaki girdi, 2×2 boyutundaki dört bölgeye bölünür ve çıktı, bu dört bölgenin maksimum sayılarıdır. Havuzlama işleminin amacı bir sonraki evrişim katmanı için giriş boyutunu küçültmektir. Bu katmanda boyuttaki küçülme sonucunda bilgi kaybı ortaya çıkar. Bu bilgi kaybı model için iki sebepten dolayı faydalıdır. İlki, bir sonraki ağ katmanlarının daha az hesapla yapmasını sağlar. İkincisi modelin verileri ezberlemesi önlenmiş olur (Hao, 2016: 420; İnik ve Ülker, 2017: 92).

### 1.3.5.1.5.3. Tam Bağlantı (Full-Connected) Katmanı

Nöronların bir dizi şeklinde görüldüğü katmandır. Tam bağlantı katmanı bir önceki katmanla ilişkili olarak oluşur. Bu katmandaki nöronların hepsi bu katmana bağlı olan önceki katmandaki aktivasyonların tamamına tam bağlı durumdadır. Tam bağlantı katmanıyla nesnelere belirleyebilmek için ele alınacak özelliklerin hangi sınıfla ilişkili olduğu belirlenir. Tam bağlı katmanlar bir sınıfla ilişkisi fazla olan yüksek seviyeli özellikleri ele alır. Bu özellikler belirten ağırlıkları içeren nöronlara bakılarak hangi sınıfa ait olduğu belirlenir (Doğan ve Türkoğlu, 2019: 418).



Şekil 20. Tam bağlantı katmanı mimarisi (Doğan ve Türkoğlu, 2019: 418).

### 1.3.5.1.6. Evrişimli Sinir Ağları Mimarileri

#### 1.3.5.1.6.1. LeNet-5 Mimarisi

Günümüzde nesne tanımak için kullanılan evrişimli sinir ağlarının çoğu LeCun ve arkadaşları tarafından geliştirilen temel mimariye dayanmaktadır. Bu temel mimari  $32 \times 32$  piksel boyutlarındaki görüntülerden rakamları okumak için kullanılan LeNet-5 mimarisi olarak bilinir. Bu mimari  $32 \times 32$  boyutundan oluşan girdi katmanından, üç tane  $5 \times 5$  evrişim katmanından, iki tane  $2 \times 2$  havuzlama katmanından bir tane tam bağlantı katmanından ve 10 boyutunda çıktı katmanından oluşur (Altenberger ve Lenz, 2018: 9).

#### 1.3.5.1.6.2. AlexNet

Krizhevesky ve arkadaşları 2012 yılında görüntü tanıma ve sınıflandırma için AlexNet mimarisi önermişlerdir. Evrişimli sinir ağlarının farklı kategorilerdeki görüntülere uygulayabilmek için öznetelik çıkarma aşamalarının sayısı LeNet'te beşten AlexNet'te yediye çıkarılmıştır (Alzubaidi vd., 2021: 26).

#### 1.3.5.1.6.3. ZFNet (Zeiler and Fergus 2014)

2013 yılında düzenlenen ImageNet yarışmasını Matthew Zeiler ve Rob Fergus tasarlamış olduğu ZFNet mimarisi ile birinci olmuştur. Bu model ile nesne tanıma modellerindeki hata oranı %11,2'ye düşürülmüştür. Bu mimari AlexNet mimarisini daha da geliştirilmiş yapısıdır (İnik ve Ülker, 2017: 98).

#### **1.3.5.1.6.4. GoogLeNet**

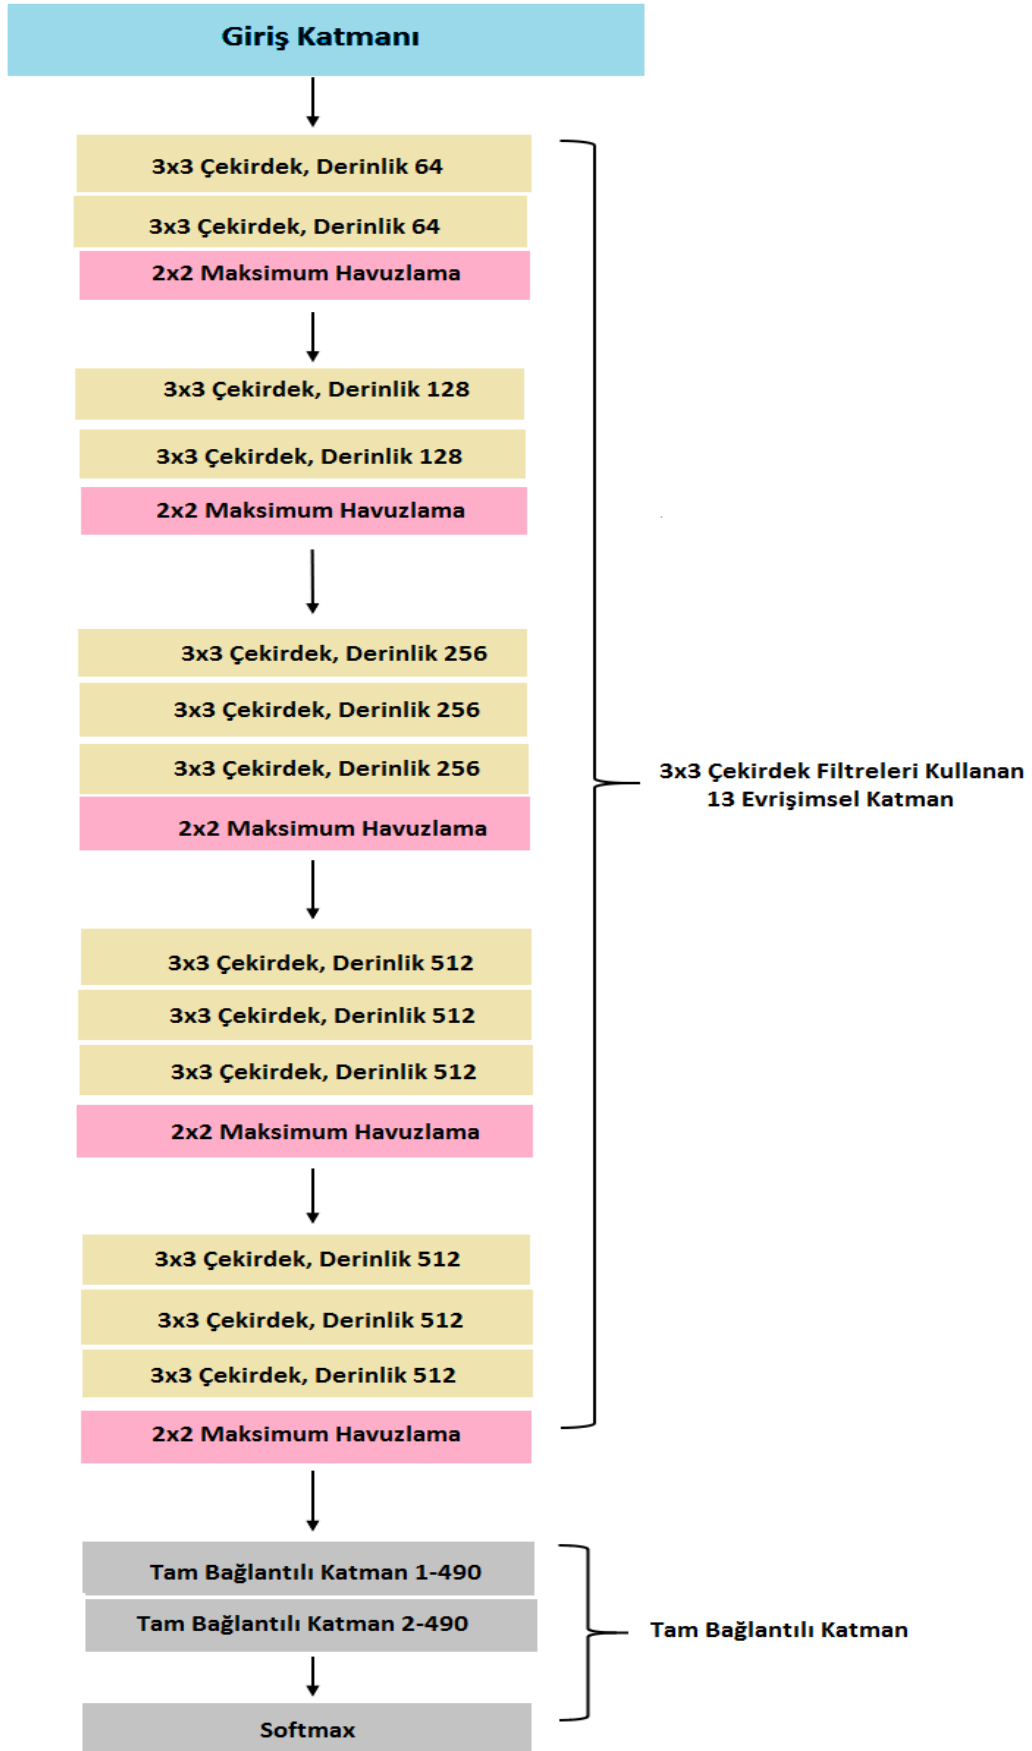
22 katmanlı ve %5,7 hata oranı gösteren GoogLeNet 2014 İmageNet yarışmasında göstermiş olduğu başarılar ile yarışmayı kazanmıştır. Bu mimari yalnızca evrişim ve havuzlama katmanlarından oluşan modern evrişimli sinir ağlarının ilk kullanımı olarak kabul edilir (Bezdan ve Dzakule, 2019: 448; İnik ve Ülker, 2017: 98).

#### **1.3.5.1.6.5. VGG (Görsel Geometri Grubu)**

Evrişimli sinir ağlarının başarıları ortaya çıktıktan sonra Simonyan ve Zisserman tarafından evrişimli sinir ağları için kolay ve verimli bir model önerilmiştir. Bu yenilikçi tasarıma Görsel Geometrik Grubu (VGG) olarak isimlendirilmiştir. ZefNet ve AlexNet'ten 19 katman daha derin ve çok katmanlı bir yapıya sahiptir (Alzubadi vd., 2021: 30).

#### **1.3.5.1.6.6. VGG-16**

Karen Simonyan ve Andrew Zisserman, 2014 yılında Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağ makalelerinde VGG-16 mimarisini tanıtmışlardır. Model 13 evrişim katmanı, 2 tam bağlantı katmanı ve 1 tane softmax sınıflandırıcı katmanından oluşmaktadır. Aşağıda Şekil 21'de VGG-16 mimarisi gösterilmiştir.



Şekil 21. VGG-16 mimarisi (Tammina, 2019: 146).

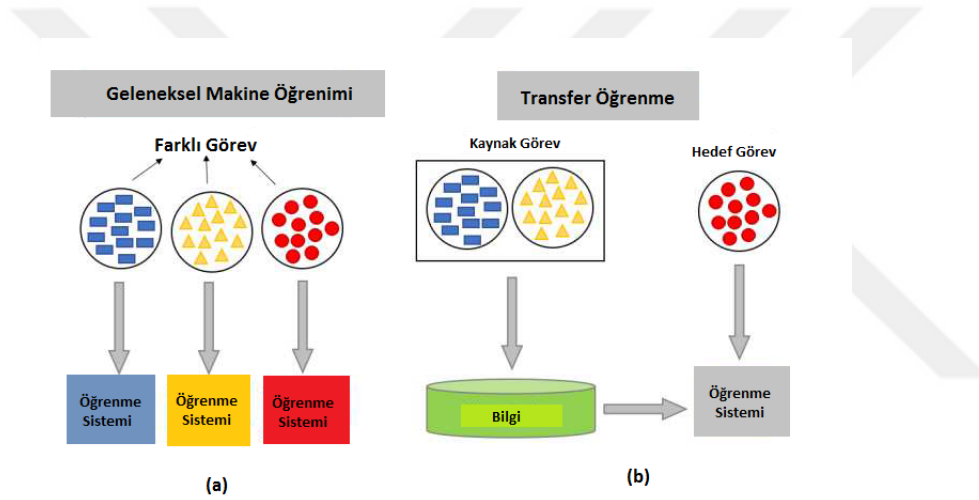
Şekil 21’de gösterilen VGG-16 mimarisini yapısı şu şekilde özetlenebilir.

- Birinci ve ikinci evrişim katmanları 64 özniteliğe sahip  $3 \times 3$  boyutunda çekirdek filtreden oluşur. Giriş görüntüsü (3 derinliği olan RGB (Kırmızı, Yeşil, Mavi) görüntüsü) birinci ve ikinci evrişim katmanına geçerken, boyutlar  $224 \times 224 \times 64$  olarak değişir. Daha sonra elde edilen çıktı, 2. adımda maksimum havuzlama katmanına iletilir.
- Üçüncü ve dördüncü evrişim katmanları 124 özniteliğe sahip  $3 \times 3$  boyutunda çekirdek filtreden oluşmaktadır. Bu iki katman, adım 2 ile maksimum havuzlama katmanını izler ve elde edilen çıktı  $56 \times 56 \times 128$ 'e düşürülür.
- Beşinci, altıncı ve yedinci katmanlar, 256 özellik haritası kullanan çekirdek boyutu  $3 \times 3$  olan evrişimli katmanlardır. Bu katmanları, adım 2 ile bir maksimum havuzlama katmanını izler.
- Sekiz ile on üçüncü evrişim katmanları 512 özniteliğe sahip  $3 \times 3$  çekirdek boyutundan oluşur. Bu katmanları, adım adım 1 tane havuzlama katmanı izler.
- On dört ve on beş katmanları, 4096 birimlik tamamen bağlı gizli katmanken on altıncı katman softmax çıktı katmanıdır (Tammina, 2019: 146).

### 1.3.6. Aktarmalı (Transfer) Öğrenme

İnsanlar, bilgiyi farklı faaliyetler arasında aktarmak için içsel bir beceriye sahiptir. Belirli bir problemi çözerken edindiğimiz bilgi farklı problemleri çözmek içinde aynı şekilde kullanabilir. Transfer, bir öğrencinin bir bağlamda bilgi veya becerilere hakim olmasının, bu bilgi veya beceriyi farklı bir bağlamda uygulamalarını sağladığı bilişsel bir uygulamadır. Aktarma yoluyla öğrenme kavramı eğitim psikolojisinden gelmektedir. Psikolog C.H. Judd’nin teorisine göre aktarmayı öğrenmek deneyimin gerçekleşmesini sağlamaktır. Kişi deneyimlerini genelleştirdiği sürece bir durumdan diğerine geçişi gerçekleştirmesi mümkündür. Bu teoriye göre aktarmalı öğrenmenin ön koşulu, iki öğrenme etkinliği arasında bir bağlantı olmasıdır. Gerçek hayatta da aktarmalı (transfer) öğrenmenin birçok örneği karşımıza çıkmaktadır. Örneğin elmaları tanıyan birinin armutları tanınması daha kolay olacaktır. Benzer şekilde elektronik org çalmayı bilen bir kişi piyano çalmayı daha kolay öğrenecektir. Aktarmalı (transfer) öğrenme ile insanlar yeni sorunlarına daha iyi ve hızlı çözümler üretebilmek için daha önce öğrenilen bilgileri kullanmaktadır. Makine öğrenimi ve derin öğrenme algoritmaları, geleneksel olarak belirli bir özellik alanı dağılımı için çalışmak üzere tasarlanmıştır. Özellik alanı dağılımı değiştiğinde, modellerin sıfırdan yeniden tasarlanması gerekir ve gerekli eğitim

verilerini toplamak da zahmetli bir iştir. İdeal makine öğrenimi senaryosu, test verileriyle aynı dağılıma sahip çok sayıda etiketli eğitim örneğinin olmasıdır. Ancak, yeterli eğitim verisi toplamak çoğu zaman pahalı ve zaman alıcıdır. Sonuç olarak, eğitim sırasında derin öğrenme modelleri yeterli etiketli veriye ihtiyaç duyduğundan dolayı denetimli öğrenme için çok az etiketli veriden oluşan bir makine öğrenimi tabanlı model oluşturmak neredeyse imkânsızdır. Bu gibi durumlarda, aktarmalı (transfer) öğrenim, öğrenme performansını önemli ölçüde iyileştirmektedir. Aktarmalı(transfer) öğrenimin arkasındaki ana fikir, bir makine öğrenimi algoritmasının ilgili alanda daha yüksek performans elde etmesine yardımcı olmak için bazı ilgili alanlardan çıkarılan etiketli verileri veya bilgileri ödünç almaktır (Pan ve Yang, 2009: 1346; Tammina, 2019: 143; Zhuang vd., 2020: 1).



Şekil 22. Geleneksel makine öğrenimi ve transfer öğrenimi arasındaki öğrenme süreçlerinin karşılaştırmalı diyagramı (Tammina, 2019: 143).

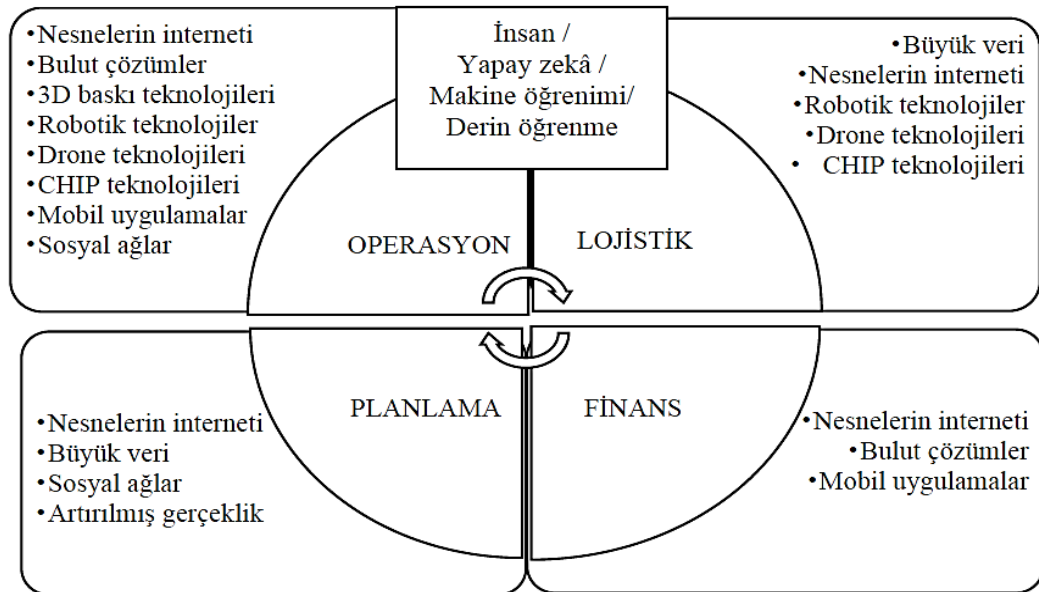
Şekil 22, geleneksel makine öğrenimi ve transfer öğrenimi süreçleri arasındaki karşıtlığı göstermektedir. Geleneksel bir makine öğreniminde görebileceğimiz gibi, her bir farklı görevi farklı öğrenme sistemiyle ayrı ayrı öğrenmeye çalışırken, aktarmalı (transfer) öğrenme, bilgiyi önceki kaynak görevlerden, denetimli öğrenmesi için çok az etiketli veriye sahip olan ikinci bir hedef görevi çıkarmaya çalışır.

### 1.3.7. Afet Yönetimi Alanında Yapay Zekâ Kullanımı

Yapay zekâ uygulamaları teknolojinin gelişmesi, büyük verilerin ortaya çıkması, verilerin işlenmesi ve analizlerini gerçekleştirebilmesi gibi avantajları ile birçok alanda olduğu gibi afet yönetimi alanında da kullanımı giderek yaygınlaşan yöntemler haline

gelmektedir. Afet yönetimi alanında büyük veriler olarak uydu görüntüleri, insansız hava araçları ile toplanan görüntüler, sosyal medya verileri, GPS verileri ve nesnelerin interneti gibi çok sayıda kaynak karşımıza çıkmaktadır. Uydu görüntüleri ile sel, deprem ve heyelan afetleri sonrasında hasarların boyutu belirlenebilmektedir. Yine sosyal medyadan toplanan veriler ile afet sonrasında ihtiyaç sahiplerinin belirlenmesinde ve kurtarma faaliyetlerinin yürütülmesinde önemli katkılarda bulunmaktadır. İnsansız hava araçları ile çekilen hava görüntüleri uydu görüntülerine ve uzaktan algıma sistemlerine kıyasla daha hızlı ve daha doğru çıkarımlar yapan sistemler olarak kullanımları günden güne yaygın hale gelmektedir (Yu vd., 2018: 5-7). Afet yönetimi alanında büyük verilerin kullanılması ile etkili bir afet yönetiminin gerçekleştirilmesi için büyük verilerin en kısa sürede elde edilmesi, yönetilmesi ve işlenmesi gerekmektedir. Bu hacimli verilerden yararlı ve güvenilir bilgilerin çıkarılıp analiz edilmesi yapay zeka yöntemleri ile mümkün hale gelerek afet yönetiminde etkili bir karar destek sisteminin oluşmasını sağlamaktadır (Sun vd., 2020: 2).

Afet yönetimi alanında da afetlerden önce hazırlık, tahmin ve erken uyarı sistemlerinde, afet anında afetlerin çevreye ve topluma vermiş olduğu etkileri ve kayıpları azaltabilme, afet sonrasında ise hasar tespit çalışmalarında büyük veri ve yapay zeka uygulamalarının başarılı sonuçları ile Şekil 23'te Levent Memiş ve Cenay Babaloğlu'nun afet yönetimi alanında kullanılan teknolojik uygulamaların araştırılması ile önermiş olduğu yeni teknoloji tabanlı afet yönetim sistemi yer almaktadır.



Şekil 23. Teknoloji tabanlı afet yönetim şeması (Memiş ve Babaoğlu, 2020: 787).


Tablo 7. Afet yönetiminde büyük veri uygulamaları (Arslan vd., 2018: 5-6).

<b>Çalışma</b>	<b>Afet Türü</b>	<b>Kullanılan Yöntem</b>	<b>Bulgular</b>
Kar erimesi ile oluşan seller için erken uyarıları sisteminin oluşturulması.	Sel	CBS, Küresel Konumlandırma Sistemi (GPS)	Jeoinformatik, Nesnelerin İnterneti (IoT) ve bulut hizmetlerine dayalı bir yaklaşım sundu.
Bulut sunucularına ve mesajlaşma modülüne dayalı otonom bir acil durum uyarı sisteminin uygulanması.	Deprem ve Yangın	GPS, bulut sunucusu, Arduino ve Mysql veritabanları	Önerilen prototip sistem, uyarıların twitter tarafından otonom olarak dağıtılmasıyla afetlere karşı farkındalık sağlamaktadır.
Afetlerin ardından acil insan hareketliliği için bir simülasyon tasarlamak.	Deprem	-	İnsan acil durum hareketliliğinin genel modelinin simülasyonu ve doğrulanması.
Afet yönetimi için sosyal büyük verilerin gerçek zamanlı izlenmesi.	Sel, Yangın ve Patlamalar	GPS ve belge veritabanları	Tasarlanan sistem Twitter verilerini tarar, afetle ilgili tweetleri gerçek zamanlı olarak analiz eder ve afet eğilimlerini bir haritada görüntüler.
Zigbee ve bulut hizmetlerine dayalı bir afet gözetim sisteminin geliştirilmesi.	-	Hadoop ve Zigbee	Zigbee tabanlı tıkanıklık kontrol modeli, afetlerin gerçek zamanlı izlenmesi ve afetlerin gerçek zamanlı tahmini için oluşturulmuştur.
Felaket bulutu veri yönetimi için genel bir Hizmet Olarak Bilgi (KaaS) çerçevesinin geliştirilmesi.	-	İlişkisel ve NoSQL veritabanlarının kombinasyonu	Heterojen kaynaklardan gelen afetle ilgili verileri depoladı ve bunların birlikte çalışabilirliğini ve entegrasyonunu destekleyerek aramaları kolaylaştırdı.
Afet yönetimi için istatistiksel analiz gerçekleştirmek için çok kaynaklı verileri sentezleme.	Kasırga	CBS, Apache Hive, Hadoop ve Mahout, R	Olası etkileri azaltmak, afetler sırasında etkin bir şekilde müdahale, koordinasyonu sağlamak için bir çerçeve sunulmaktadır.

Tablo 7. (Devamı)

Çalışma	Afet Türü	Kullanılan Yöntem	Bulgular
Kalabalık algılama ve işaret tabanlı geçici yönlendirme kullanılarak afet toplama ve analiz sisteminin tasarımı.	-	Hadoop, HTML5	Bu sistem, gerçek zamanlı afet verilerini toplamak için tasarlanmıştır ve kullanıcılar için hızlı yerel tahliye uyarısı oluşturur.
Felaket müdahalesi için bir jeo-uzamsal anlamsal ağda performansı iyileştirmek.	-	Harita indirgeme	Önerilen yaklaşım, afet müdahale uygulamalarında bireysel uzamsal sorgu yürütme süresini azaltır.
Web'deki sosyal medya ve cihaz verilerine dayalı sis afet analizi.	Sis	-	Önerilen çerçeve, insanların davranışları ve sis afetinin azaltılması için hükümetin strateji tasarımları hakkında rehberlik sağlar.
Şehir acil kurtarma için büyük veri bilişinin kavramsal olarak oluşturulması.	Yangın	-	Bir afet sırasında yardımcı karar verme yeteneğini geliştirmek için acil durumları simüle etmek için büyük ölçekli bir etkinlik mekanı 3B simülasyon senaryoları oluşturulur.
Taşkın bilgi yönetimi için büyük veri analitiğine dayalı bir erken uyarı sisteminin geliştirilmesi.	Sel	Semantik ağlar ve ontolojiler	Nehirlerin yağış miktarı ile su seviyesi arasında ilişki seviyesi, sel oluşumu belirlenmesi.

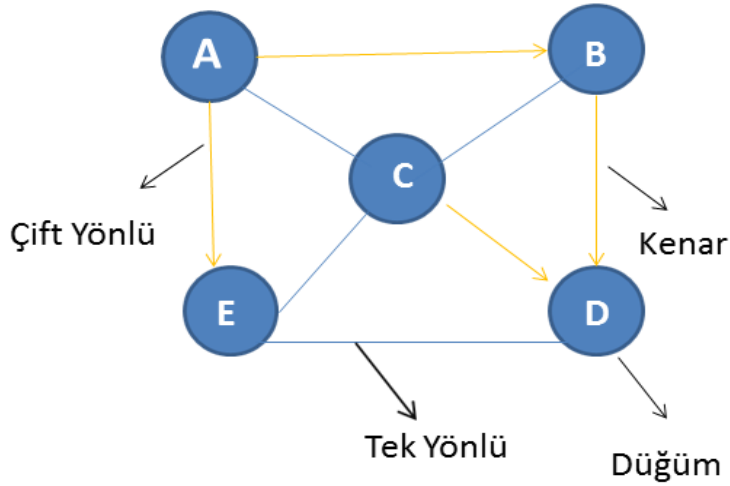
Göstermiş olduğu başarılarından dolayı yapay zekâ uygulamaları afet yönetiminde hazırlık, zarar azaltma, müdahale ve iyileştirme aşamalarında yapılan çalışmalar ve kullanılan yöntemler Şekil 24'te de görüldüğü üzere gün geçtikçe daha fazla çalışmalar yapılarak kullanım alanları yaygınlaşmaktadır.



Şekil 24. Yıllara göre afet yönetimi alanında yapılan yapay zeka çalışmaları (Sun vd., 2020: 7).

#### 1.4. En Kısa Yol Algoritması

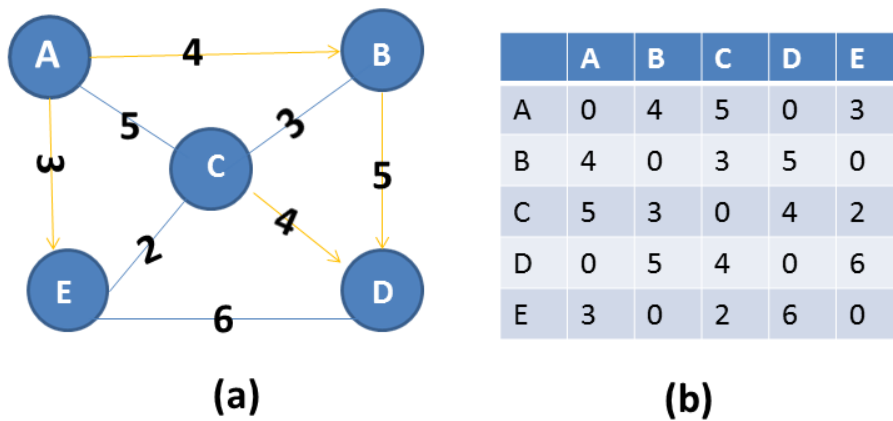
Temelleri graf teorisine dayanan en kısa yol algoritmasının temel amacı mevcut yolları temsil eden düğümler arasındaki mesafeyi en aza indirmektir. Optimal bir en kısa yol, bir kaynaktan bir hedefe olan minimum uzunluk kriterine sahip olmalıdır. Günümüzde sosyal ağlarda yol bulmada, ağ yönlendirme protokollerinde, rota planlama, trafik kontrolü ve ulaşım sistemlerinde yaygın olarak kullanılmaktadır. En kısa yol algoritması dikkate alındığında çeşitli graf türleri bulunmaktadır. Genel bir graf köşeler ve kenarlardan oluşan matematiksel bir nesnedir. Graf yönlendirilmiş veya yönlendirilmemiş kenarlar içerebilir. Kenarlar üzerindeki ağırlıklar pozitif veya negatif değerler olabilir. Değerler, problemin türene bağlı olarak tam sayı ya da reel sayı değerlerini alabilir (Madkour vd., 2017: 1).



Şekil 25. Basit bir graf modeli

Şekil 25'teki graf örneğinde A, B, C, D olmak üzere 5 düğümlü ve 8 kenarlı bir graf modelidir. Modelde ok işareti ile gösterilen yollar (A ile B, A ile E, B ile D, C ile D) çift yönlü yolları temsil ederken, düz çizgi ile gösterilen yollar ise (A ile C, C ile E, B ile C, E ile D) tek yönlü yolları temsil etmektedir.

Eğer bir grafın üzerindeki kenarların her biri farklı bir sayısal değer alabiliyorsa bu graf modeline maliyetli graf modeli denilmektedir. Düğümler arasındaki bağlantıyı göstermek için kullanılan kare matrise komşuluk matrisi denilmektedir. Komşuluk matrisi yolların maliyet değerlerinden meydana gelmektedir (Çölkesen, 2002 den Aktaran, Günbatar, 2008: 9).



Şekil 26. Maliyetli graf (a) ve komşuluk matrisi (b) örneği (Günbatar, 2008: 9).

En kısa yolu belirlemek için tam sayılı ve doğrusal programlamalı bir model oluşturulduğunda ise şu şekilde formüle edilebilir. Ağırlıklar, kaynaklar (s) ve hedefler (w)  $\in V$  ile yönlendirilmiş bir ağ verildiğini varsayalım. En kısa yolu bulmak için aşağıdaki optimizasyon problemini tanımlayabiliriz.

$$\min \sum_{u,v} x_{uv} w_{uv} \quad (\text{Eşitlik 1})$$

Bağlı olarak:

$$\sum_u x_{su} - \sum_v x_{vs} = 1 \quad (\text{Eşitlik 2})$$

$$\sum_u x_{vt} - \sum_u x_{tu} = 1 \quad (\text{Eşitlik 3})$$

$$\sum_q x_{pq} - \sum_r x_{rp} = 0, \text{ için } \forall p \in V - \{s, t\} \quad (\text{Eşitlik 4})$$

$$x = 0 \text{ ya da } 1 \quad (\text{Eşitlik 5})$$

Buradaki x ağdaki kenarı ifade eder en kısa yoldaysa 1 değilse 0 değerini alır ve w ise karşılık gelen kenarın ağırlığıdır. Amaç fonksiyonu (Eşitlik 1), kat edilen toplam mesafenin minimizasyonunu belirtir. Kısıtlama (Eşitlik 2), kaynaktan tek bir nokta olduğunu ve hedeften kaynağa dönüşün olmadığını ifade eder. Kısıtlama (Eşitlik 3), hedefin tek bir noktadan geldiğini ve hedeften kaynağa dönüşün olmadığını ifade eder. Kısıtlama (Eşitlik 4), herhangi bir düğümde bir girdi veya çıktı olmasını ya da girdi veya çıktı olmamasını sağlar. Kısıtlama (Eşitlik 5), değişkenlerin integral alanını empoze eder.

## 2. LİTERATÜR ÖZETİ

### 2.1. Deprem Sonrası Meydana Gelen Yol Hasarları

Yol ağırları deprem sonrası tahliye, acil yardım ve kurtarma işlemleri için hayati öneme sahipti (Balyemez ve Berköz, 2005: 11). Dünya genelinde ve ülkemizde meydana gelen yıkıcı depremler sonucunda yol ağlarında ağır hasarlar meydana gelmiş ve bu hasarlar sonucunda depremin sosyal ve ekonomik kayıpları artmıştır.

Türkiye'nin en yıkıcı depremlerinden olan 1999 Düzce depreminde Bolu Dağı E-5 karayolunda hasar meydana gelmiştir. Bu hasar sonucunda ilk yardım malzemelerinin ve kurtarma ekiplerinin bölgeye ulaşımı zorlaşarak zararların artmasına yol açmıştır. Yine 1999'da meydana gelen İzmit depreminde bölgeden geçen Anadolu Otoyolunun İzmit Doğu Kavşağı-Akyazı bölümünde oto yol gövdesinde çatlaklar, çökmeler ve derin yarıklar meydana gelmiştir. Devlet İl Yolları kapsamında İstanbul-Ankara, İzmit-Gölcük-Yalova, Sakarya-Bilecik, Hendek-Kocaeli, Akyazı, Dokurcun-Mudurnu, Adapazarı-Karasu, Bursa-Yalova, Bursa-Karacabey, Bursa-Mudanya, Mudanya-Zeytinbağı, Bursa-Gemlik, Bursa-İnegöl, İznik-Karamürsel yollarında, köy yollarında ve köprülerde hasar meydana gelmiştir. Marmara depremi sonrasında alt yapılarda meydana gelen hasarın ekonomik değeri 1.5 milyar dolar olarak rapor edilmiştir (Balyemez ve Berköz 2005: 4; Özmen 2000:70; TMMOB 2010: 11).



Şekil 27. 12 Kasım 1999 Düzce depremi E-5 Bolu geçişi karayolu hasarı (Balyemez ve Berköz, 2005: 4).



Şekil 28. Kocaeli depremi viyadük çökmesi (Sucuoğlu, 2000: 10).

23 Ekim 2011 Van depreminden sonra kara yollarında çatlaklar ve deformasyonlar meydana gelmiştir. Depremlerden sonra ikincil afet olarak 77 tane heyelan meydana gelmiştir. Bu heyelanlar sonucunda Van- Ağrı karayolunda ve köy yollarında hasarlar meydana gelmiştir (Akyüz vd., 2011: 11; Taşkın vd., 2012: 297).

24 Ocak 2020 yılında Elazığ'da meydana gelen 6.7 büyüklüğündeki depremden sonrada kara yollarında çatlaklar meydana gelmiştir (Çetin vd., 2020: 14).

## 2.2. Yol Hasar Tespiti İle İlgili Yapılan Çalışmalar

Literatürde yapılan çalışmalara baktığımızda genellikle günlük hayatta meydana gelen yol çatlakları ve çukurların tespit edilebilmesine yönelik çalışmalara sık rastlanırken afet ya da deprem sonrası meydana gelen yol hasarlarının tespiti ile ilgili yapılan çalışmalara az rastlanılmaktadır. Yapılan çalışmalarda genellikle veri setlerinin oluşturulmasında uzaktan algılama ve uydu görüntüleri kullanılmıştır. Literatür incelenmiş olup hem günlük hayattaki yol hasarı hem de afet sonrası meydana gelen yol hasarının tespit edilmesi ile ilgili yapılan çalışmaların bazıları şunlardır;

Md. Shohel Arman ve arkadaşları, 2020 yılında kara yolu hasarı tespiti ve sınıflandırılması için evrişimli sinir ağları ile bir araştırma gerçekleştirmişlerdir. Hasarları çukur, çatlak ve sökülmüş asfalt olmak üzere üç kategoride sınıflandırmışlardır. Verilerini akıllı telefon ile çekilen 1100 yol görüntü ile oluşturmuşlardır. Araştırmalarında R-CNN ve hızlı R-CNN modellerini kullanmışlar ve ikisi arasında karşılaştırma yapmışlardır. Karşılaştırma sonucunda hızlı R-CNN modeli %98.88 doğruluk oranı ile daha iyi sonuca ulaşmıştır (Arman vd., 2020).

Baolin Yang ve arkadaşları, 2019 yılında afetlerden sonra yollardaki enkazları ve ikincil afet olarak meydana gelen heyelanların neden olduğu yol tıkanıklığını tespit etmek için VHR uydu görüntüleriyle CNN tabanlı görüntü tanıma ve sınıflandırma yöntemi önermişlerdir. Deprem sonrası VHR uydu görüntülerinin 80.000 eğitim için 20.000 doğrulama verisi olarak kullanarak CNN modellerini eğitmişlerdir. Eğitim sonucunda %77,60 kappa puanıyla ve %87,95 F1 doğruluk oranına ulaşmışlardır (Yang vd., 2019).

Hatice Balcı 2019 yılında kara yolundaki hasarların otomatik tespiti için derin öğrenme modellerinden SSD (Single Shot multibox Detector, Tek Çekim Görüntüde Çoklu Kutu Algılayıcı) ile bir çalışma gerçekleştirmiştir. Önceden yayınlanmış 9.053 görüntüden oluşan bir veri seti ile model eğitilmiştir. Eğitim sırasında VGG16, VGG19, normalize edilmiş VGG16 ve normalize edilmiş VGG19 olmak üzere 4 farklı model kullanılmıştır ve modellerin performansları karşılaştırılmıştır. Karşılaştırma sonucunda VGG16 modelinin doğruluk oranı en yüksek çıkmıştır (Balcı, 2019).

Sukhad Anand ve arkadaşlar, 2018 yılında otonom çatlak ve çukur tespiti için evrişimli sinir ağı mimarisi kullanarak yeni bir model önermişlerdir. Modellerinin eğitimi için iki farklı veri seti kullanmışlardır. Modellerinin eğitim aşamasından sonra modeli test etmek için otonom araca monteli kamera ile yolun görüntülerini almışlardır. Yol bölümlene ve diğer ön işleme aşamaları için Squeeze-Net'i (SegNet) kullanarak yol çatlaklarını ve çukurları doğru bir şekilde tespit etmişlerdir (Anand vd., 2018).

Emre Dandıl ve arkadaşları, 2019 yılında yol kusurlarının derin öğrenme kullanılarak tespit edilmesi için bir yöntem önermişlerdir. Yol kusurlarından oluşan 9053 görüntüden oluşan bir veri seti oluşturmuşlardır. Çalışmalarında Tensorflow' un kütüphanesi olan SSD Inception V2 Coco ile ön-eğitilmiş bir ağ modeli kullanılarak yoldan alınan görüntüler il eğitmişlerdir. Çalışmalarında B-ESA tabanlı bir sistem önermişlerdir. Yol bozukluklarının tespit edilmesi için B-ESA eğitim aşaması için Labellmg ile etiketleme gerçekleştirmişlerdir. Yapılan test işlemleri ile 8 farklı sınıftaki yol bozukluklarını yüksek başarı ile tespit etmişlerdir (Dandıl ve Kuran, 2019).

Laha Ale ve arkadaşları, 2018 yılında çeşitli yol hasarlarını etkili bir şekilde tespit etmek için RetinaNet tabanlı bir yaklaşım önermişlerdir. Çalışmalarında RetinaNet modellerini DenseNet, ResNet, VGG ve InceptionResNetV2 dâhil olmak üzere farklı modellerle eğitip karşılaştırmışlardır. Modellerin eğitimini akıllı telefonlarla elde edilen gerçek veri seti ile gerçekleştirmişlerdir. Önerilen RetinaNet yaklaşımıyla yol

hasarlarının yüksek doğruluk oranıyla tespit edildiği sonucuna ulaşmışlardır (Ale vd., 2018).

M. Izadi ve arkadaşları, 2017 yılında depremden sonra yollardaki bina enkazlarını, park halindeki arabaları ve devrilen ağaçların tespiti için yarı otomatik bir yöntem önermişlerdir. Çalışmalarında depremden sonra Quickbird uydu görüntülerinden faydalanmışlardır. Hasar tespitinde optimum özellik seçimi için genetik algoritma (GA) kullanmışlardır. Ardından destek vektör makinesi (SVM) ile nesnelere tespit etmişler ve belirli sınıflara ayırarak bir sınıflandırma yapmışlardır. Hasar seviyelerinin belirlenmesi için FIS ve ANFIS tabanlı iki farklı akıllı karar destek sistemi kullanmışlardır. Çalışmalarının sonucunda hasarlı yolların tespitinde %93 genel doğruluk ve 0.91 kappa katsayısına ulaşmışlardır (Izadi vd., 2017).

Lei Zhang ve arkadaşları, 2016 yılında yol çatlak tespiti için derin öğrenme tabanlı bir yöntem önermişlerdir. Akıllı telefonla toplanan, 3264 x 2448 boyutunda 500 görüntüden oluşan bir veri setini kullanmışlardır. Modellerinde SVM (destek vektör makinesi), Boosting(Güçlendirme) ve CNN (evrişimli sinir ağları) olmak üzere üç farklı model kullanmışlar ve karşılaştırma yapmışlardır. Karşılaştırma sonucunda en iyi çatlak tespit performansını 0.8696 doğruluk oranıyla CNN modeli göstermiştir (Zhang vd., 2016).

Keishi Yamaguchi ve Hitoshi Saji, 2012 yılında büyük ölçekli depremler ve depremlerden sonra meydana gelen tsunamilerin yol ağlarına verdiği hasarı belirlemek ve yol güvenliğini analiz etmek için uydu görüntülerini kullanarak bir çalışma yapmışlardır. Enkazlı ve hasarlı yolları NDVI (bitki örtüsü çıkarımı) yöntemi ile belirlemişlerdir. Su basmış alanları ise kara yüzey su endeksi (LSWI) yöntemini kullanarak belirlemişler ve bu iki yöntem ile hasarlı yolları belirlemişlerdir (Yamaguchi ve Saji, 2017).

M. Kawamura ve arkadaşları, 2010 yılında uydu görüntüleri ve uzaktan algılama sistemleri ile depremlerden sonra meydana gelen karayolu ve demiryolu hasarı tespiti için bir çalışma yapmışlardır. Çalışmalarında SPOT-5 uydu görüntülerini kullanarak arazi örtüsü değişikliği ve bitki örtüsü değişikliğini gösteren NDVI indeksini kullanmışlardır. Deprem öncesi ve deprem sonrası uydu görüntüleri ile NDVI görüntü farkını hesaplayan istatistiksel bir doku analizi uygulamışlardır. Uydu görüntülerini ve NDVI doku analizi yöntemiyle karayolu hasarının ve demiryolu hasarının tespit edilmesiyle acil ulaşım yollarını gösteren CBS (coğrafi bilgi sistemi) geliştirmişlerdir. Yaptıkları vaka çalışması ile büyük afetlerden sonra hasar tespitinin yapılabileceği ve

acil ulaşım rotalarının belirlenebileceğini sonucuna ulaşmışlardır (Kawamura vd., 2017).

Xiaoli Liu ve arkadaşları, 2013 yılında afet bölgelerinde yol hasarını belirlemek için nesne tabanlı uzaktan algılama ve görüntü sınıflandırma yöntemiyle bir çalışma gerçekleştirmişlerdir. Çalışmalarında ilk olarak, görüntülerdeki nesnelere anlamak için piksel tabanlı, çok ölçekli segmentasyon teknolojisini kullanmışlardır. İkinci olarak, yol bilgileri (uzunluk, genişlik, alan, hasar oranı) ile nesne odaklı ve çoklu sınıflandırma yöntemini kullanmışlardır. Çalışmalarında Çin'in Sichuan Eyaletindeki Lushan İlçesinde 7 büyüklüğündeki depremin ardından SPOT-5 görüntüleri ve insansız hava görüntülerini deney verileri olarak kullanmışlardır. Deney sonucunda yolları, tamamen hasarlı yollar, kısmen hasar görmüş yollar ve hasar görmemiş yollar olarak tespit etmişlerdir (Liu vd., 2013).

### **3. MATERYAL VE YÖNTEMLER**

#### **3.1. Problemin Durumu**

Geçmişten günümüze insanlar, canlarına ya da mallarına zarar veren doğa ve insan kaynaklı olaylarla karşı karşıya kalmışlar ve bu olaylar insanlar için afet boyutuna ulaşarak yıkıcı etkilere sebep olmuştur. Dünyada ve Türkiye’de meydana gelen geçmiş afetlere baktığımızda en yıkıcı ve en ölümcül afet türü olarak karşımıza depremler çıkmaktadır. Depremler sonrasında heyelan, yangın, kaya düşmesi ve salgın hastalık gibi ikincil afetler de meydana gelerek depremlerin zararlarını arttırmaktadır. Depremler meydana geldikleri bölgede birçok sistemin çökmesine ya da hasar görmesine neden olmaktadır. Bu sistemler yaşam hattı sistemleri olarak da adlandırılan ulaşım, iletişim, su temini, elektrik temini, gaz temini ve petrol taşımacılığı gibi alt yapı sistemlerini ifade etmektedir. Yol ağları yaşam hattı sistemlerinde kritik bir öneme sahiptir. Afet yönetiminde, afet öncesi, afet sırası ve afet sonrasında ulaşım ağları önemli bir rol oynamaktadır. Deprem sonrasında etkili, hızlı ve koordineli bir afet yönetiminin sağlanabilmesi etkilenen bölgedeki gerçek zamanlı yol durum bilgilerinin mevcudiyetine bağlıdır. Deprem sonrası kara yolu hasar durumunun hızlı ve doğru bir şekilde değerlendirilmesi deprem bölgelerine acil durum ekiplerinin hızla ulaşım olaya müdahale etmesini ve afet yardımı için insan gücü veya insani yardım malzemelerinin olay yerine ulaşma süresini kısaltabilecektir. Zamanında yapılan bir arama ve kurtarma çalışması ile afet bölgelerindeki can ve mal kayıplarını azaltılabilecektir. Bu nedenle deprem bölgelerindeki hasarlı yolların en kısa sürede belirlenmesi ve afet bölgesine yakın diğer rotaların hızla oluşturulması gerekmektedir.

#### **3.2. Araştırmanın Amacı**

Çalışmanın amacı; afet bölgesindeki hasar görmüş kara yollarının en kısa sürede tespit edilmesi ve afet bölgesine en yakın hasar görmemiş bir diğer güzergâhı belirleyen hibrit bir model oluşturmaktır. Bu model, afet bölgelerine acil durum ekiplerini ve insani yardım malzemelerini en hızlı ve güvenli bir şekilde ulaştırılması sağlayarak can ve mal kayıplarını en aza indirmeyi hedeflemektedir.

### 3.3. Araştırmanın Önemi

Günümüzde depremlerden sonra meydana gelen yol hasarlarının belirlenmesi için uzaktan algıma sistemleri, uydu görüntüleri, helikopterden çekilen görüntüler ya da bölgedeki acil durum ekiplerinin gözlemleri kullanılmaktadır. Olay sonrasında toplanan bu görüntüler uzmanlar tarafından yorumlanarak geleneksel hasar tespit yöntemleri ile yol hasarları belirlenmektedir. Kullanılan bu yöntemler zaman alıcı ve doğruluğu ise uzmanlara bağlıdır. Yüksek çözünürlüklü uydu görüntülerin yol hasar tahminlerinde kullanılması durumunda kara yolu ağları; nehirler, demir yolu hatları veya ağaç çitleri gibi diğer etmenlerle karıştırılabilmektedir. Yine uydu görüntülerinin olumsuz hava koşullarında kullanabilmek ve hasarların çıkarımının yapılabilmesi oldukça zordur. Depremlerden sonra sadece tek bir veri kaynağı kullanılarak çıkarımlar yapılamamakta ve sosyal ağlar gibi birçok büyük veriler açığa çıkarak durumu değerlendirmeyi zorlaştırmaktadır. Acil durum ekiplerinin olay yerindeki gözlemleri ise zaman alıcı ve sınırlı bölgeleri içeren değerlendirmelerdir. Geleneksel yöntemler ile yol hasarlarının belirlenmesi zaman alıcı bir yöntemken yine afet bölgesine yakın hasarsız yolları belirlemek de uzun süre gerektiren yöntemler ile sağlanarak olaya müdahaleyi geciktirmektedir. Bu çalışmada oluşturulan hibrit model, afet bölgelerine gönderilen insansız hava araçları ya da dronlara takılan kameralar ile toplanan görüntüler ile hasarlı yolların tespiti en kısa sürede yapılarak klasik en kısa yol algoritması ile afet bölgesine en yakın diğer yollar belirlenebilecektir. Bu sayede:

- Olumsuz hava koşullarında bile yol hasarları en kısa sürede belirlenebilecek,
- Uzaktan algılama sistemleri ve uydu görüntüleri gibi büyük veri içeren yöntemlere göre zamandan tasarruf sağlanacak,
- Dış etmenlerden dolayı yapılan yanlış yol hasarı tespiti oranı azaltılacak,
- İnsansız hava araçları ile toplanan görüntüler ile hasarlı ve hasarsız yollar eş zamanlı olarak belirlenebilecek,
- Afet bölgesine yakın hasarsız ve güvenli yollar en hızlı şekilde belirlenerek acil durum ekiplerine bildirilecek,
- Olay meydana geldiği anda ivedilikle veriler işlenerek olaya en hızlı müdahale sağlanacak,
- Hızlı ve etkili bir tahliye ya da arama kurtarma işleme sağlanarak en fazla sayıda afet zedenin hayatı kurtarılacaktır.

### **3.4. Araştırmanın Özgün Değeri ve Literatüre Katkısı**

Literatürde yapılan çalışmalar incelendiğinde karşımıza sınırlı sayıda çalışma çıkmaktadır. Literatürdeki yapılan çalışmalar incelenmiştir ve yapılan çalışmaların çoğunda yol hasar tespiti için uydu görüntüleri, uzaktan algılama görüntüleri ve vektör yol haritası (OpenStreetMap) gibi büyük veriler içeren ve olumsuz koşullardan ya da dış etmenlerden çabuk etkilenen yöntemler kullanılmıştır. Literatürde yapılan çalışmaların sadece bir tanesinde insansız hava araçları ile toplanan görüntüler kullanılarak yapılan çalışma mevcuttur. Yapılan çalışmaların tümü sadece yol hasarı tespiti amacıyla yapılmışlardır ve hiçbir çalışmada rotalama işlemi yapılmamıştır. Bizim çalışmamız ise evrişimli sinir ağları ile otomatik yol hasar tespitinin yapılması ve afet bölgelerine yakın rotalar belirlenmesi ile literatürde yeni ve özgün bir çalışma olarak yerini alarak bu alandaki boşluğu dolduracaktır.

### **3.5. Araştırmanın Kapsamı**

Yapay zekâ alanında makine öğrenmesinin alt dalı olan derin öğrenme yöntemine ait görüntü işleme amacıyla kullanılan evrişimli sinir ağları ile girdi olarak verilen yol görüntüleri sayesinde yolları hasarlı (kullanılamaz) ve hasarsız (kullanılabilir) olarak sınıflandırabilen ve bu sınıflandırma sonucunda klasik en kısa yol algoritması üzerinden hasarlı yolların çıkartılıp afet bölgesine yakın en kısa rotanın belirlenmesi için model oluşturulması çalışmanın kapsamı olarak belirlenmiştir.

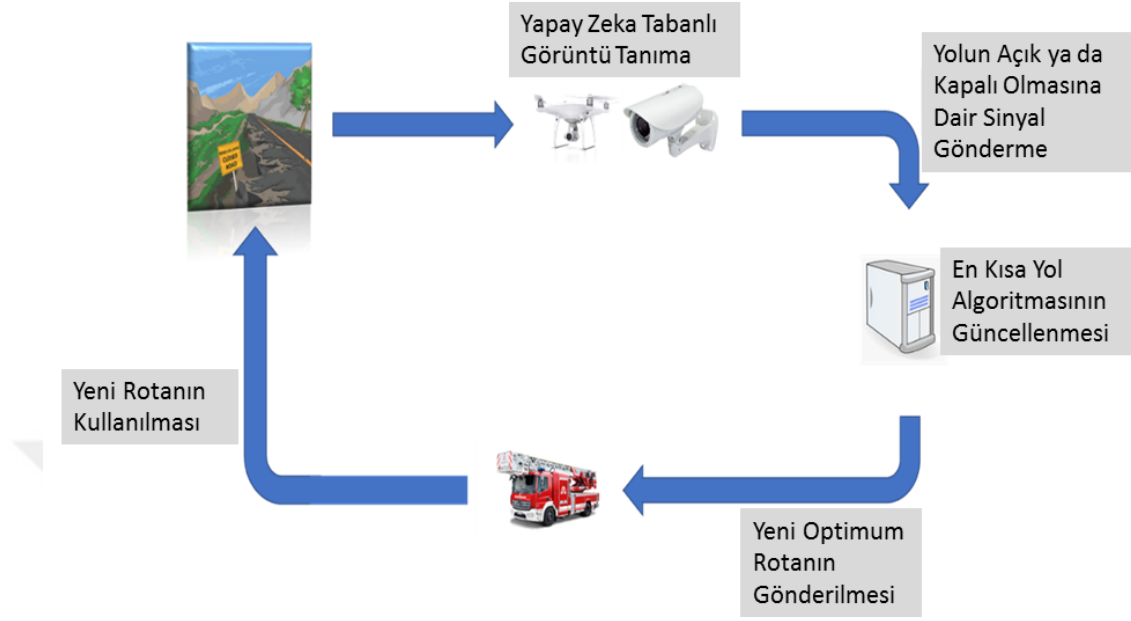
### **3.6. Araştırmanın Kısıtlılıkları**

Çalışmadaki veri olarak kullanılan yol görüntüleri image.google.com gibi açık kaynaklardan toplanmıştır. Verilerin toplanması aşamasında insansız hava araçları ile çekilen görüntülere ve çözünürlüğü yüksek görüntüleri bulmakta zorlanılmıştır. Özellikle çalışmamızda deprem sonrası kullanılmayacak kadar hasar gören yol görüntülerinin azlığı ve daha fazla görüntüye ulaşamaması çalışmanın kısıtlılıklarındandır.

### **3.7. Araştırmanın Modeli**

Öncelikle araştırmaya verilerin toplanmasıyla başlanarak, toplanan veriler evrişimli sinir ağları ile algoritmalara dönüştürüldükten sonra yollar açık ve kapalı olarak sınıflandırılmaktadır. Kapalı yolların belirlenmesi ile rotalar en kısa yol

algoritması üzerinden çıkartıldıktan sonra yeni optimum yolun belirlenmesi ve acil durum ekiplerine bildirilmesi ile model tamamlanmaktadır.



Şekil 29. Araştırmanın modeli

### 3.8. Veri Toplama Araçları ve Yöntemleri

Bir afet sonrasında hasar gören kullanılmayan yolları içeren açık bir veri kümesi bulunmamasından dolayı kendimiz açık kaynaklardan toplamış olduğumuz görüntüler ile bir veri seti oluşturduk. Bu çalışmanın amacına uygun depremlerden sonra araç geçişine uygun olmayan yol resimleri ile araç geçişi için sorun teşkil etmeyen yol resimleri toplanmıştır. Resimler manuel olarak images.google.com gibi çeşitli kaynaklardan toplanmıştır. Çalışmamızda kullanılan hasarlı yol resimlerinde dikkat ettiğimiz nokta, yollardaki hasarların trafik geçişine izin vermeyecek kadar hasarlı olmasıdır. Hafif çatlaklar bulunan yollar trafik geçişine uygun olduğundan bu çalışmaya dâhil edilmemiştir. Çalışmada veri olarak 248'i hasarlı, 304'ü normal olmak üzere; toplamda 552 resim kullanılmıştır. Toplanan verilerin %70'i evrişimli sinir ağları ile oluşturulan modelin eğitim seti için kullanılırken, verilen %15'i doğrulama setinde ve %15'i ise test setinde kullanılmıştır. Modelin epoc (eğitim turu) sayısı farklı değerler arasından en iyi sonucun elde edildiği 100 değeri seçilmiştir. Batch size (eğitim aşamasında kaç tane verinin işleneceği) ise 16 olarak ayarlanmıştır.

Çalışmanın ilk aşamasında 248'i hasarlı yo görüntüsü ve 304'ü normal yol görüntüsü olmak üzere toplamda 542 görüntü kullanarak görüntüleri kapalı yol ve açık

yol olarak etiketlenerek ikili bir sınıflandırma modeli oluşturulmaya çalışılmıştır. Bu aşamada 5000 sınıfın üzerinde 3.2 milyondan fazla resim bulunan ImageNet veri tabanı üzerinden önceden eğitilmiş VGG-16 mimarisi kullanılmıştır. Veri sayısının azlığı bir dezavantaj olmakla birlikte bu dezavantaj transfer öğrenme yöntemi kullanılarak en aza indirgenmeye çalışılmıştır.

Çalışmanın ikinci aşamasında ise evrişimli sinir ağı modeli ile klasik en kısa yol algoritması bir birine entegre edilmiştir. Evrişimli sinir ağı modeline 100 gibi yüksek bir ceza terimi eklenerek hasarlı olarak tespit edilen yol ağları rotalar üzerinden ceza terimi sayesinde çıkartılarak klasik en kısa yol algoritması ile rotalar arasındaki en kısa mesafeli yolu bulmak amaçlanmıştır.



Şekil 30. Hasarlı ve normal yolları içeren veri örnekleri

Çalışmanın ilk aşamasındaki VGG-16 modeli ile oluşturulan sınıflandırma modeli sınıflandırma modellerinde en çok kullanılan değerlendirme metriklerinden olan duyarlılık, özgüllük ve G-ortama değerlendirme metrikleri ile değerlendirilerek sonuçlar karşılaştırılmıştır.

- Duyarlılık puanı: Çalışmamızdaki sınıflayıcının kapalı yol olarak etiketlenen verilerin ne kadarının doğru tahmin ettiğinin bir ölçüsüdür. Gerçek pozitif değerlerinin doğru tahmin ölçüsü olarak tanımlanabilir.
- Özgüllük puanı: Çalışmamızdaki sınıflayıcının açık yol olarak etiketlenen verilerin ne kadarını doğru tahmin ettiğinin bir ölçüsüdür. Gerçek negatif değerlerinin doğru tahmin ölçüsü olarak tanımlanabilir.
- G-ortalama puanı: Modelin hem duyarlılık puanında hem de özgüllük puanında nasıl performans gösterdiği hakkında bilgi verir.

#### 4. BULGULAR VE TARTIŞMA

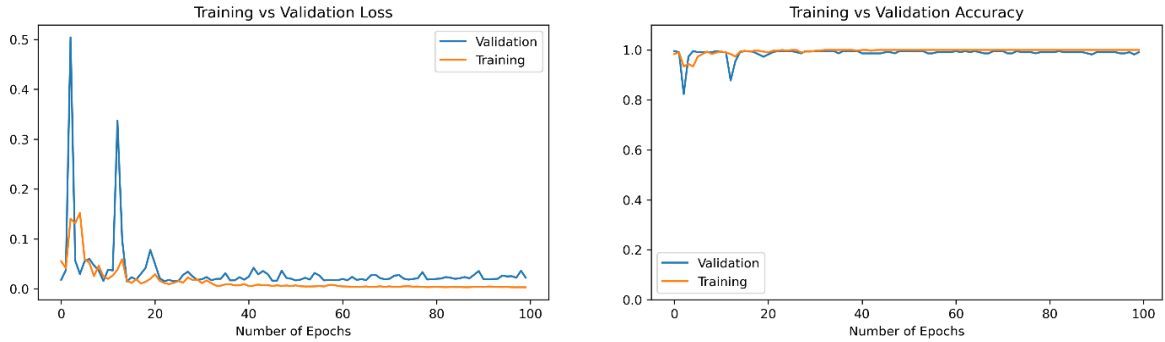
Çalışmada ikili sınıflandırma ve klasik en kısa yol algoritması ile evrişimli sinir ağlarının birbirine entegrasyonu detaylı olarak ayrı ayrı incelenecektir.

Çalışmanın ilk aşaması için yollar açık yol ve kapalı yol olmak üzere ikili olarak sınıflandırılmıştır. Bu sınıflandırma sonucunda VGG-16 ile oluşturduğumuz model test setinde %97 oranında doğruluk elde etmiştir.

Çalışmamızın ikinci aşamasında ise evrişimli sinir ağları ile kapalı olan yollar belirlendikten sonra oluşturulan model üzerinden hasarlı yollar evrişimli sinir ağlarının atadığı ceza terimi ile hasarlı yollar çıkartılıp klasik en kısa yol algoritması kullanılarak tüm yollar arasından en kısa güzergâh belirlenmiştir.

##### 4.1. İkili Sınıflandırmanın Bulguları ve Yorumları

Çalışmanın bu aşamasında yol görüntüleri üzerinden açık yol ve kapalı yol olmak üzere ikili bir sınıflandırma yapılmıştır. Bu aşamada 248 kullanılmayacak kadar hasar görmüş yol görüntüleri ve 304 normal yol görüntüsü olmak üzere toplamda 552 görüntü kullanılmıştır. Çalışmada epoch (eğitim turu) sayısı farklı değerler arasından en iyi performansı gösteren 100 sayısı seçilmiştir. Şekil 28’de epoch (eğitim turu) sayısının eğitim ve doğrulama setleri üzerinde kaybını ve doğruluğunu göstermektedir.



Şekil 31. VGG-16 modelinin epoch (eğitim turu) sayısına göre eğitim ve doğrulama kaybının değerleri

Şekil 31’e göre her iki çizelgede de epoch (eğitim turu) sayısı arttıkça modelin performansı daha iyi hale gelmektedir. VGG-16 modelinin eğitim ve doğrulama setindeki üstünlüğü de şekilde görülmektedir.

Model oluşturulduktan sonra, eğitilmiş bir VGG-16 modeli eğitim ve doğrulama setlerinde test edilmiş ve modelin kayıp ve doğruluk performansı Tablo 8’de gösterilmektedir.

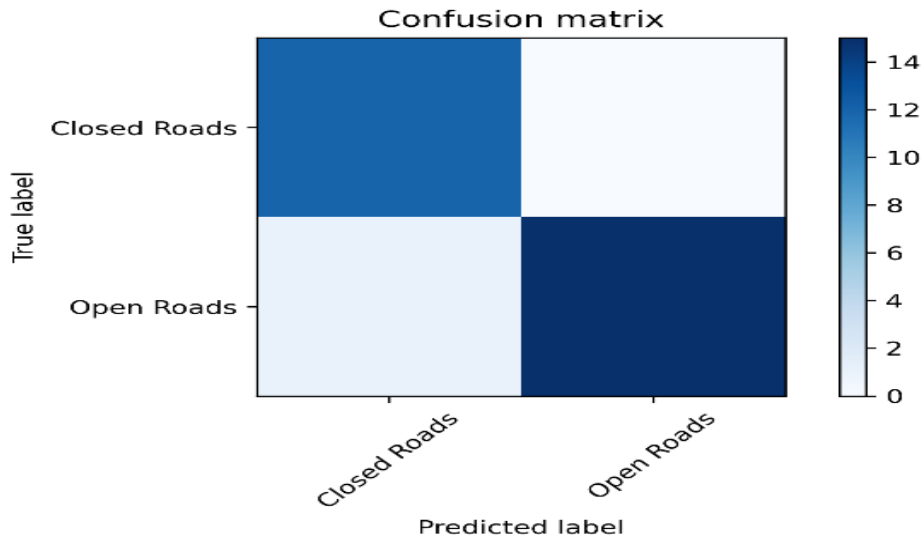
Tablo 8. VGG-16 modelinin eğitim ve doğrulama setindeki performansı

<b>Kayıp ve Doğruluk Değerlendirmesi</b>	<b>Performans</b>
Validation Loss (Doğrulama Kaybı)	0.02253
Validation Accuracy(Doğrulama Doğruluğu)	0.990
Train Loss (Eğitim Kaybı)	0.00299
Train Accuracy (Eğitim Doğruluğu)	1.0

Makine öğrenmesinde bir modelin iyi çalışıp çalışmadığının en önemli göstergesi o modelin test setindeki göstermiş olduğu performansla belirlenmektedir. Modelin eğitim ve doğrulama setindeki performansı bize modelin eğitimi hakkında bilgi verirken test setindeki performansı ise modelin gerçek problemler karşısındaki performansını göstermektedir. Test setindeki performans modelin daha önce görmemiş olduğu veri setleri üzerinde nasıl çalıştığının bir göstergesidir. Bizim modelimiz ise daha önce veri setindeki modelin görmediği veri setinin %5’lik kısmı ile yani 28 farklı görüntü üzerinden test edilmiştir. Tablo 9’da modelin test setindeki performansı gösterilmektedir.


Tablo 9. Test veri seti için karışıklık matrisi sonuçları

	<b>Kapalı Yol</b>	<b>Açık Yol</b>
<b>Kapalı Yol</b>	12	0
<b>Açık Yol</b>	1	15



Şekil 32. Karışıklık matrisi çizimi

Matris sonuçları incelendiğinde modelimiz 12 tane kapalı yollardan 12 tanesini kapalı olarak tahmin ederken 16 tane açık yollardan 15 tanesini açık 1 tanesini ise kapalı olarak tahmin etmiştir. Eğer modelimiz kapalı yollardan 1 tanesini açık olarak tahmin etmiş olsaydı bu durum afetzedeler ve acil durum ekipleri için sorun yaratabilecekken açık yollardan bir tanesini kapalı olarak tahmin edilmesi afetzedeler ve acil durum ekipleri için herhangi bir sorun teşkil etmeyecektir.



Şekil 33. Modelin ROC eğrisi

Tablo 9, Şekil 32 ve Şekil 33'e göre modelin en iyi performansı göstermiş olduğu sonucuna varabiliriz. Model tüm kapalı yolları doğru bir şekilde tahmin ederken, kapalı yollardan ise sadece bir tanesini kapalı olarak tahmin etmiştir. Bu çalışmanın amacına uygun olarak kapalı yollardan bir tanesini açık olarak tahmin etmektense açık yollardan bir tanesini kapalı olarak tahmin etmek tercih edilebilir.

Aşağıdaki Tablo 10'da da görüldüğü üzere modelin test seti üzerindeki performansı kayıp ve doğruluk değerleri açısından oldukça başarılı sonuçlar göstermiştir. Test setindeki tahmin değerlerine bağlı olarak model diğer değerlendirme ölçütlerinde de başarılı sonuçlar göstermiştir. Tablo 11'de görüldüğü üzere model duyarlılık, özgüllük ve G-ortalama değerlendirme metriklerinden sırasıyla 0.923, 1, 0.960 gibi yüksek doğruluk sonuçları elde etmiştir.

Tablo 10. Modelin test setindeki performansı

<b>Kayıp ve Doğruluk Değerlendirmesi</b>	<b>Performans</b>
Test Kaybı (Test Loss)	0.07403
Test Doğruluğu (Test Accuracy)	0.9642

Tablo 11. Duyarlılık, özgülük ve G-ortalama açısından modelin performansı

<b>Değerlendirme Metrikleri</b>	<b>Performans</b>
Duyarlılık (Sensitivity)	0.923
Özgüllük (Specificity)	1
G-Ortalama (G-Mean)	0.960

Modelin G-ortalama puanının yüksek olması modelin her iki sınıfa ait örneklerin doğru bir şekilde sınıflandırabileceğinin bir göstergesidir. Test setinde yüksek bir puanın alınması modelin güvenilirliğini arttırmaktadır. Modelin göstermiş olduğu bu başarı hibrit sistemin verimli çalışabilmesi için çok önemlidir. Revize edilmiş en kısa yol algoritmasının uygulanması için en önemli parametreden biri modelin doğru tahminleridir. Doğru tahminler sonucunda hibrit sistem yüksek doğruluk oranıyla çalışabilir.

#### 4.2. CNN Modeli İle Klasik En Kısa Yol Algoritmasının Birbirine Entegrasyonu

Dronlara takılan kameralar ile toplanan görüntüler üzerinden evrişimli sinir ağları ile ikili bir sınıflandırma yapıldıktan sonra evrişimli sinir ağları kapalı yolları 1 olarak açık yolları ise 0 olarak tahmin edecektir. Afet bölgelerine giden en kısa yolu bulmak için ise evrişimli sinir ağları ile klasik en kısa yol algoritması aşağıdaki gibi birbirine entegre edilmiştir.

$$\min \sum_{u,v} x_{uv} w_{uv} + M x_{uv} \rho_{CNN} \quad (\text{Eşitlik 6})$$

Bağlı Olarak:


$$\sum_u x_{su} - \sum_v x_{vs} = 1 \quad (\text{Eşitlik 7})$$

$$\sum_u x_{vt} - \sum_u x_{tu} = 1 \quad (\text{Eşitlik 8})$$

$$\sum_q x_{pq} - \sum_r x_{rp} = 0, \text{ için } \forall p \in V - \{s, t\} \quad (\text{Eşitlik 9})$$

$$x = 0 \text{ ya da } 1 \quad (\text{Eşitlik 10})$$

Buradaki  $x_{ij}$  ağdaki kenarı ifade eder en kısa yoldaysa 1 değilse 0 değerini alır,  $w_{ij}$  karşılık gelen kenarın ağırlığıdır ve M ise büyük bir sabit sayıdır ve ceza değişkeni olarak adlandırılır. CNN algoritmasının tahminine göre 0 veya 1 değerini alabilen  $\rho_{CNN}$  ceza süresinin aktivasyonu olarak adlandırılabilir. Tahmin 1 ise ceza süresi etkinleştirilecektir 0 ise ceza süresi etkinleştirilmeyecektir. Evrişimli sinir ağları ile bir yol kapalı olarak tahmin ediliyorsa ceza terimi sayesinde en kısa yol hesaplamasından çıkartılacaktır. Model Şekil 34’teki hibrit model üzerinden Tablo 12 ve Tablo 13’te anlatılacaktır.



Şekil 34. Hibrit model örneği

Şekil 34’teki hibrit sistem üzerinden bir deprem sonrasında A noktasındaki acil durum ekibinin B noktasındaki afet bölgesine ulaşması gerektiğini varsayarsak. A ile B noktası arasındaki tüm rotalar acil durum ekiplerinin sisteminde mevcut olacaktır. A noktası ile B noktası arasındaki yollarda herhangi bir hasar oluşmadığında yolların mesafesi hibrit modele göre hesaplanacaktır. Tablo 12’de yolların hesaplaması gösterilmiştir. Koyu yazı ile yazılan rota A ile B noktası arasındaki en kısa mesafeli yolu göstermektedir.

Tablo 12. A ile B arasındaki herhangi bir yolda hasar meydana gelmediği durumda en kısa yolun belirlenmesi

Tüm Rotalar	Amaç Fonksiyonu= $\min \sum_{u,v} x_{uv} w_{uv}$
A→1→4→7→B	$1x(3 + 3 + 5 + 3) = 14$
A→1→4→6→B	$1x(3 + 3 + 4 + 4) = 14$
A→2→5→6→B	$1x(4 + 2 + 3 + 4) = 13$
A→2→5→9→B	$1x(4 + 2 + 5 + 3) = 14$
<b>A→3→9→B</b>	<b><math>1x(3 + 6 + 3) = 12</math></b>

Tablo 12’ye göre model A ile B arasındaki herhangi bir yolda trafik geçişine izin vermeyecek derece hasar tespit etmediğinden dolayı evrişimli sinir ağları ceza terimini etkinleştirmemiştir.

A ile B arasındaki rotalardan 3→9 da trafik geçişine izin vermeyecek kadar hasar meydana geldiğini varsayalım. Dronlara takılan kameralar ile görüntüler toplanıp evrişimli sinir ağları ile bu rota kapalı yol olarak belirlenecektir. Evrişimli sinir ağları 1000 gibi yüksek bir ceza terimini etkinleştirerek tahminlerini  $\rho_{CNN} = \{0,1\}$  (0 olarak tahmin edilen yollar kullanılabilen yollarken 1 olarak tahmin edilen yollar kullanılmayan yollardır) revize edecektir. A ile B arasındaki tüm rotaların yeni mesafesi Tablo 13’e göre hesaplanacaktır. Koyu yazıyla yazılan rota en kısa rotadır.

Tablo 13. A ile B arasındaki bir yolda hasar meydana geldiğinde CNN algoritmasının tahmini ve en kısa yolun belirlenmesi

Tüm Rotalar	Amaç Fonksiyonu= $\min \sum_{u,v} x_{uv} w_{uv} + M x_{uv} \rho_{CNN}$
A→1→4→7→B	$1x(3 + 3 + 5 + 3) = 14$ , burada $\rho_{CNN} = 0$
A→1→4→6→B	$1x(3 + 3 + 4 + 4) = 14$ , burada $\rho_{CNN} = 0$
<b>A→2→5→6→B</b>	<b><math>1x(4 + 2 + 3 + 4) = 13</math>, burada <math>\rho_{CNN} = 0</math></b>
A→2→5→9→B	$1x(4 + 2 + 5 + 3) = 14$ , burada $\rho_{CNN} = 0$
A→3→9→B	$(1x3 + 1 \times 0 \times 1000) + (1x3 + 1 \times 1 \times 1000)$ $= 1003$ , burada $\rho_{CNN} = 1$

Tablo 13’te de görüldüğü üzere herhangi bir yolda hasar meydana geldiğinde hibrit sistem ile herhangi bir ek araştırma ya da hesaplama yapılmadan rotalar değiştirilebilir ve optimum mesafe belirlenebilir.

### 4.3. Tartışma

Haijian Ma ve arkadaşları, 2013 yılında yüksek çözünürlüklü uydu görüntüleri ve yol haritaları kullanarak otomatik yol hasar tespiti için bir yaklaşım önermişlerdir. Yol kenar çizgilerinin deprem öncesi ve deprem sonrası sabit geometrik özelliklerde olmasından dolayı, yol kenar çizgilerindeki değişimi yol hasarının olduğuna dair bir kanıt olarak kabul etmişlerdir. Yaklaşım, öncelikle depremden sonra elde edilen görüntülerden hasarsız yolun kenar çizgileri çıkartılıp ardından bu yol kenarları, yol haritalarının sağladığı depremden önceki yol çizgileri ile karşılaştırma yapmışlardır. Segment afet öncesi verilerde mevcutsa ancak afet sonrası görüntülerden çıkarılamıyorsa segmenti hasarlı bir segment olarak kabul etmişlerdir. Sonuç olarak, performans deprem sonrası QuickBird görüntüleri ile bir deneyle test etmişlerdir. Deney

sonucunda sunulan yaklaşım ile depremlerden sonra elde edilen görüntülerden yol hasarını hızlı ve doğru bir şekilde tespit etmişlerdir. Bizim çalışmamızda ise depremlerden hemen sonra meydana gelen yol hasarlarının görüntülerini kullanarak yol hasar tespitini anlık veriler ile gerçekleştirilecektir. Bu sayede de deprem öncesi yol bilgisi ve deprem sonrası yol bilgilerini içeren büyük veriler kullanılmayarak tespit süresi kısılacaktır (Ma vd., 2013).

Jianhua Wang ve arkadaşları, 2015 yılında afet sonrası uzaktan algılama görüntülerinden faydalanarak kara yolu hasar tespiti ve değerlendirilmesi için bilgiye dayalı bir yöntem önermişlerdir. Çalışma, yol merkez hattının çıkarılması, afet sonrası yolların çıkarılması, hasar tespitinin yapılması ve hasar değerlendirmesi aşamalarından oluşmaktadır. Yol merkez çizgilerini öncelikle yüksek çözünürlüklü uzaktan algılama görüntülerinden belirlemişler ve bilgi modeli ile afet sonrası yolların çıkarılması için kullanmışlardır. Mekânsal analiz ile hasarlı yolları tespit etmişler ve değerlendirme modelini esas alarak yol hasar değerlendirmesi yapmışlardır. Çalışmalarında hipotez oluşturma ve hipotez doğrulama modellerini kullanarak önerilen yöntemin yol hasarı tespiti ve değerlendirmesinde etkili olduğunu bulmuşlardır. Biz ise çalışmamızda dronlara takılan kameralar ile toplanan görüntüler üzerinden yol hasarının otomatik olarak tespit edilmesi sağlayan bir model oluşturarak uzaktan algılama görüntülerinin karayolu hasarı tespitinde ağaç gölgesi, demir yolu hattı ve ağaç çitleri gibi yol ağları ile karıştırılan hedeflerden dolayı ortaya çıkan yanlış tahminlerin yapılması engellenmiş olacaktır (Wang vd., 2015).

P. M. Kikin ve arkadaşları, 2019 yılında makine öğrenme tekniklerini kullanarak uydu görüntüsü verilerine, insansız hava araçlarına (İHA'lar) ve SAR'a dayanarak hasarı tespit etmek ve karayolu ağının durumunu ve kullanılabilirliğini tespit etmek ve haritalamak için yeni bir yaklaşım önermişlerdir. Yaklaşımlarının verileri Sentinel-1, Sentinel-2, ALOS-2, Landsat-8. uydu görüntülerini ve UAV verilerini ( Google görsellerden afetlerden sonra İHA'lar tarafından çekilen hasarlı ve normal yol görüntülerinden oluşan 1000 görüntüden oluşan bir veri seti oluşturmuşlardır.) kullanmışlardır. Tam Evrişimli Sinir Ağları (FCNN) mimarisi ile görüntülerin sınıflandırılması ve görüntülerin tanınması için modeller eğitimi gerçekleştirilmiştir. Farklı derin öğrenme modellerini karşılaştırmak için sadece optik uydu verileri, sadece SAR uydu verileri, optik uydu verileri ile SAR uydu verileri beraber ve İHA verileri kullanarak farklı modeller oluşturmuşlardır. Bu modeller arasından İHA verileri kullanarak oluşturulan model yol hasarını en iyi tahmin etmiş ve F1 puanında en iyi

sonucu göstermiştir. Bizim çalışmamızda VGG-16 modeli ile yollar üzerinde ikili bir sınıflandırma yapıldıktan sonra hasarlı yollar belirlenip güzergâhlar üzerinden bu hasarlı yollar çıkartılıp afet bölgesine yakın bir diğer yol belirlenip rotalama işlemi yapılmıştır (Kikin vd., 2019).

Ananya Gupta ve arkadaşları, 2020 yılında afetlerden sonra etkilenen alanları ve erişebilir yolların belirlenmesi için derin öğrenmeye dayalı havadan görüntü segmentasyonu ile bir çerçeve önermişlerdir. Etkilenen yol ağının tahmin etmek için OSM (OpenStreet Map) tarafından sağlanan açık verilerden yararlanmışlardır. Sınır ağlarının iki önemli çeşidi olan ENetSeparable (VGG11 ve VGG16) ile UNetUpsample (ResNet18 ve ResNet34) olmak üzere 4 farklı ağ mimarisini kullanmışlardır. Hava görüntülerinden ikili sınıflandırma ve çoklu sınıflandırma ile modellerin performanslarını analiz etmişler ve karşılaştırmışlardır. Sonuç olarak, VGG16 ağ modeli diğer tüm modellerden daha iyi performans göstermiştir. Diğer üç ağ modelinin en yüksek doğruluk oranı 73.98 iken VGG16 ağ modelinin doğruluk oranını 94.76 olarak sonuçlanmıştır. Biz çalışmamızda ise görüntüler üzerinden açık yol ve kapalı yol olarak VGG-16 modeli ile yapmış olduğumuz sınıflandırma sonucunda modelimiz %97 oranında doğruluk elde etmeyi başarmıştır. Çalışmamızda klasik en kısa yol algoritması ile yapmış olduğumuz rotalama aşaması da bu alanda yapılan çalışmalar içinde ilk çalışma olarak yerini almaktadır (Gupta vd., 2020).

## 5. SONUÇ VE ÖNERİLER

Doğa kaynaklı afet türlerinden biri olan depremler can ve mal kayıpları olarak en çok hasara sebep olan afetlerdir. Dünya genelinde meydana gelen depremlerin hasarları gelişmemiş ve gelişmekte olan ülkelerde daha ağır kayıplarla sonuçlanmıştır. Ülkemizde 1999 Marmara depremi sonrasında afet yönetimi alanında birçok yeni kanunlar çıkmış ve önlemler alınmış olsa da 2020 yılında meydana gelen Elazığ ve İzmir depremleri ülkemizin yapı stoku ve afet kültürü açısından hâlâ depremlere karşı yeterince hazırlıklı olmadığı verilen kayıplarla görülmüştür. Beklenen İstanbul depreminin yakın yıllarda gerçekleşmesi durumunda uzmanlar tarafından kayıpların daha fazla olacağı ön görülmektedir. Afetlere hazır hale gelebilmek için ise afet yönetiminin dört aşamasında da etkili planlar ve yöntemler kullanılarak afet zararları minimize edilmeye çalışılmalıdır. Kriz yönetimi aşamasında afet zararlarını en az kayıpla sınırlayabilmek için afet bölgelerine olabildiğinden en hızlı sürede ulaşım olaylara müdahale edilmelidir. Afet bölgelerine en kısa sürede ulaşılması durumunda daha fazla sayıda afetzedeyi kurtarabilir ve afet bölgesinden alınan bilgiler ile etkili bir müdahale aşaması gerçekleştirilebilir. Bu sebeple depremlerden sonra afet bölgelerine erişme bilirlilik müdahale aşamasında en önemli faktörlerdendir. Günümüzde afet bölgelerine ulaşmak için kara yolu, hava yolu, deniz yolu ve demir yolu gibi farklı ulaşım ağları kullanılabilirken en çok kullanılan ulaşım ağı olarak karşımıza kara yolları çıkmaktadır. Afetlerden sonra karayollarında meydana gelen hasarlar birçok hizmetin aksamasına sebep olmaktadır. Yol hasarlarının belirlenmesi için kullanılan geleneksel yöntemler ve uzaktan algılama sistemleri yöntemleri kullanılması yüksek maliyetli ve güvenilirliği az olan uygulamalardır. Maliyeti düşük ve güvenilirliği daha yüksek olan yeni yöntemler geliştirilmeli ve kullanımı yaygınlaştırılmalıdır.

Dijitalleşen dünya ile yapay zekâ uygulamaları birçok alanda kullanılarak insanların yaşamlarını daha kolay hale getirmektedir. Afet yönetimi alanında da kullanılan ve üstün başarılar elde eden birçok yöntem bulunmaktadır. Kullanılan bu yapay zekâ uygulamaları geleneksel yöntemler karşısında otomatik çıkarımlar yaparak önemli başarılar göstermişlerdir. Bu çalışmada, yapay zekâ uygulamalarının göstermiş olduğu avantajlar ile depremlerden sonra hasar gören kara yolları en kısa sürede tespitini yapabildiği ve afet bölgesine en yakın güzergâhtan rotalama işlemi yapabildiği otomatik bir model oluşturulması amaçlanmıştır. Afet sonrası yol hasarı ile ilgili açık veri kaynakları bulunmadığından dolayı verilerimizi images.google.com gibi açık

kaynaklardan toplayarak yeni bir veri seti oluşturulmuştur. Veri için 248'i hasarlı yol görüntüsü ve 304'ü ise normal yol görüntüsü olmak üzere toplamda 552 görüntü toplanmıştır. Modelin eğitim ve test aşaması için VGG-16 modeli kullanılmış ve yol görüntüleri üzerinden evrişimli sinir ağları ile ikili sınıflandırma yapılmıştır. Evrişimli sinir ağları ve VGG-16 mimarisi ile oluşturulan model G-ortalama, duyarlılık ve özgüllük değerlendirme metrikleri kullanılarak doğruluk açısından karşılaştırma yapılmıştır.

Çalışmamız iki aşamadan meydana gelmiştir. İlk aşamada yollar üzerinde kapalı yol ve açık yol olarak ikili bir sınıflandırma yapmak amaçlanmıştır. Modelimiz bu sınıflandırma sonucunda VGG-16 mimarisi ile %97 oranında doğruluk elde etmeyi başarmıştır. Test aşamasında modelimiz tüm kapalı yolları doğru tahmin etmiş açık yollardan ise sadece bir tanesini kapalı olarak tahmin etmiştir.

İkinci aşamasında ise evrişimli sinir ağları ile klasik en kısa yol algoritmasının birbirine entegre edilmesi ile hibrit bir taşıma sisteminin oluşturulması amaçlanmıştır. Evrişimli sinir ağları ile tespit edilen hasarlı yollar oluşturulan hibrit sistem üzerinden etkinleştirilen ceza terimi ile çıkartılarak afet bölgesine ulaşılacak tüm güzergâhlar çıkartılıp en kısa yol algoritması ile en kısa güzergâh belirlenmiştir. Bu aşamada da evrişimli sinir ağları ve klasik en kısa yol algoritması ile başarılı sonuçlar elde edilmiştir.

Modelimizin kısıtlılıklarına baktığımızda ise hasarlı yollarla ilgili çok fazla sayıda görüntüye ulaşamamış olmamızdır. Eğer model daha fazla sayıda veri ile eğitilip test edilirse daha iyi sonuçlara ulaşılacaktır.

Hızla gelişen teknoloji ile afet öncesinde tahminlerde bulunabilmek ve afet yönetimi evrelerinde otomatik çıkarımlar yapabilmek için bu alanda yapay zekâ uygulamaları ve kullanımları genişletilmelidir.

## KAYNAKÇA

- AFAD, 2020 yılı doğa kaynaklı olay istatistikleri. 11 Ağustos 2021 tarihinde [https://www.afad.gov.tr/kurumlar/afad.gov.tr/e\\_Kutuphane/Istatistikler/2020yilidogakaynakliolayistatistikleri.pdf](https://www.afad.gov.tr/kurumlar/afad.gov.tr/e_Kutuphane/Istatistikler/2020yilidogakaynakliolayistatistikleri.pdf) adresinden erişildi.
- Afet ve Acil Durum Yönetimi Başkanlığı (2014). Açıklamalı afet yönetimi terimleri sözlüğü. *Deprem Dairesi Başkanlığı*, Ankara.
- Adams, J. (2002). *Environmental health in emergencies and disasters: a practical guide*. World health organization.
- Akdag, S. E. (2002). Mali yapı ve denetim boyutlarıyla afet yönetimi (Disaster management in terms of financial and monitoring aspects). *Sayıştay Araştırma/İnceleme/Çeviri Dizisi*, 20.
- Akyüz, S., Zabcı, C. ve Sançar, T. (2011). Preliminary report on the 23 October 2011 Van earthquake. *Faculty of Mines, Istanbul Teknik Üniversitesi, Istanbul, 2011*.
- Ale, L., Zhang, N. ve Li, L. (2018). Road damage detection using RetinaNet. In *2018 IEEE International Conference on Big Data*, 10-13 December 2018, USA, s. 5197-5200.
- Alexander, D. E. (2005). An interpretation of disaster in terms of changes in culture, society and international relations. E.L. Quarantelli (Der), *What is a disaster?* içinde (ss. 25-37). United States of America, Xlibris Press.
- Altenberger, F. ve Lenz, C. (2018). A non-technical survey on deep convolutional neural network architectures. *arXiv preprint arXiv:1803.02129*.
- Altun, L., Kara Ö., Akgün A., Babur E. ve Kezik U. (2016). Doğu Karadeniz Bölgesinde meydana gelen güncel heyelanlar ve olası çözüm önerileri. *Ulusal Heyelan Sempozyumu Tebliğler*, 27-29 Nisan 2016, Ankara.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O. ve Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 1-74.
- Anand, S., Gupta, S., Darbari, V. ve Kohli, S. (2018). Crack-pot: autonomous road crack and pothole detection. In *2018 Digital Image Computing: Techniques and Applications (DICTA)*, s. 1-6, IEEE.
- Arman, M. S., Hasan, M. M., Sadia, F., Shakir, A. K., Sarker, K. ve Himu, F. A. (2020). Detection and classification of road damage using R-CNN and faster R-CNN: a deep learning approach. In *International Conference on Cyber Security and*

- Computer Science* Springer, 30 July 2020, Cham, Social Informatics and Telecommunications Engineering ICONCS 2020, vol 325, Springer, ss.730-741.
- Arı, A. ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Arslan, M., Roxin, A. M., Cruz, C. ve Ginhac, D. (2018). A review on applications of big data for disaster management. In *2017 13th International Conference on Signal-Image Technology ve Internet-Based Systems (SITIS)*, 9 January 2018, India, s. 370-375, IEEE.
- Atalay, M. ve Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Aydın, İ. H. ve Değirmenci, C. H. (2018). *Yapay zekâ*. Girdap Kitap, ISBN 9789752429420, İstanbul, 20s.
- Aylak, B. L., Oral, O. ve Yazıcı, K. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımını. *El-Cezeri Journal of Science and Engineering*, 8(1), 74-93.
- Balcı, H. (2019). Road damage detection with deep learning methods. Yayımlanmamış yüksek lisans tezi, Gazi Üniversitesi, Ankara.
- Balyemez, S. ve Berköz, L. (2005). Hasar görebilirlik ve kentsel deprem davranışı. *İtüdergisi/a Mimarlık, Planlama, Tasarım*, 4(1): 3-14.
- Barber, D. (2012). *Bayesian reasoning and machine learning*. Cambridge University Press.
- Baxter, S. J. (2000). *Earthquake basics*. Delaware Geological Survey, University of Delaware Newark, Special Publication No. 23, Delaware, s. 7.
- Bezdan, T. ve Dzakula, N. (2019). Convolutional neural network layers and architectures. in *sinteza. 2019-International Scientific Conference on Information Technology and Data Related Research*, 2019, Serbia, Singidunum University, s. 445-451, DOI: <https://doi.org/10.15308/Sinteza-2019-445-451>.
- Borana, J. (2016). Applications of artificial intelligence ve associated technologies. *Proceeding of International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science [ETEBMS-2016]*, 5-6 March 2016, s. 64-67.
- Bozüyük, T., Yağci, C., Gökçe, İ. ve Akar, G. (2005). Yapay zeka teknolojilerinin endüstrideki uygulamaları. Marmara Üniversitesi, İstanbul.

- Carter, W. N. (2008). *Disaster management a disaster manager's handbook*. Asian Development Bank, ISBN 978-971-561-006-3, Philippines, s. 53-57.
- Civalek, Ö. (2005). Optimum yapı dizaynında yapay zeka yaklaşımlar. *Deprem Sempozyumu*, s. 1325-1334.
- Coppin, B. (2004). *Artificial intelligence illuminated*, Jones and Bartlett publishers, ISBN 0-7637-3260-3, America, 285s.
- Coppola, D. P. (2006). *Introduction to international disaster management*, Elsevier, ISBN 0-7506-7982-4, America, s. 1-22.
- Coşkun, A. (2007). Yapay zeka optimizasyon teknikleri: literatür değerlendirmesi. *Fırat Üniversitesi Doğu Araştırmaları Dergisi*, 5(2), 142-146.
- CRED, (2017). Natural disasters, 10 Ağustos 2021 tarihinde [https://cred.be/sites/default/files/adsr\\_2017.pdf](https://cred.be/sites/default/files/adsr_2017.pdf) adresinden erişildi.
- CRED, (2018). Natural disasters, 10 Ağustos 2021 tarihinde <https://www.cred.be/sites/default/files/CREDNaturalDisaster2018.pdf> adresinden erişildi.
- CRED, (2019). Natural disasters, 10 Ağustos 2021 tarihinde [https://cred.be/sites/default/files/adsr\\_2019.pdf](https://cred.be/sites/default/files/adsr_2019.pdf) adresinden erişildi.
- CRED, (2020). Technological disasters, 29 Ağustos 2021 tarihinde <https://cred.be/sites/default/files/CC60.pdf> adresinden erişildi.
- CRED, (2021). Disaster year in review 2020 global trends and perspectives, 10 Ağustos 2021 tarihinde <https://cred.be/sites/default/files/CredCrunch62.pdf> adresinden erişildi.
- CRED ve UNDRR, (2019). Disasters report, 10 Ağustos 2021 tarihinde <https://reliefweb.int/report/world/human-cost-disasters-overview-last-20-years-2000-2019> adresinden erişildi.
- Çeber, K. (2005). Mali yönüyle afet yönetimi. Yayımlanmamış yüksek lisans tezi, Süleyman Demirel Üniversitesi, Isparta.
- Çetin, K. Ö., İlgaç, M., Can, G., Çakır, E. ve Söylemez, B. (2020). 24 January 2020, Sivrice-Elazığ-Turkey earthquake reconnaissance report, Ankara.
- Çoban, H. (2019). Afet sonrası iyileştirme planı hazırlanması. *Resilience Journal*, 3(2), 239-246.
- Dandıl, E. ve Kuran, E. (2019). Karayolu Kusurlarının Derin Öğrenme ile Tespit Edilmesi. 2nd International Conference on Data Science and Applications (ICONDATA 19), October 3-6, Balıkesir.

- Daniş, H. ve Görgün, M. (2005). Marmara depremi ve tüpraş yangını. *Deprem Sempozyumu, 23-25 Mart 2005, Kocaeli*, s. 1362-1369.
- Doğan, F. ve Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(2)*, 409-445.
- Dölek, İ. (2016). *Türkiyenin fiziki coğrafyası*, Pegem Akademi, ISBN 978-605-318-064-7, Ankara, ss. 311-64.
- EM-DAT. (2020). 3 Ağustos 2021 tarihinde <https://www.emdat.be/frequently-asked-questions> adresinden erişildi.
- Ergen, M. (2019). What is artificial intelligence? Technical considerations and future perception. *Anatolian J. Cardiol, 22(2)*, 5-7.
- Ergünay, O. (1998). Afet Yönetimi Emergency Türkiye 93 First International Disaster Relief and Prevention, Civil Defence, Public Security and First Aid Exhibition, November 23 (27), 2s.
- Ergünay, O. (2007). Türkiye'nin afet profili. TMMOB Afet Sempozyumu Bildirileri, 5-7 Aralık 2007, Ankara, s. 1-14.
- Ergünay, O. (2009a). Afet yönetimi: genel ilkeler, tanımlar, kavramlar. ss 1-49.
- Ergünay, O. (2009b). Doğal afetler ve sürdürülebilir kalkınma. Deprem Sempozyumu, 11-12 Kasım 2009, Abant, s. 11-12.
- Tevfik, E. ve Değerliyurt, M. (2009). Türkiye'de Afet Yönetimi. *Doğu Coğrafya Dergisi 22*: 147-64.
- Grahmani, Z. (2003). Unsupervised learning in: Bousquet O., von Luxburg U., Ratsch G. (eds) *Advanced Lectures on Machine Learning, Lecture Notes in Computer Science*, vol 3176, Springer, Berlin, s. 72-112, [https://doi.org/10.1007/978-3-540-28650-9\\_5](https://doi.org/10.1007/978-3-540-28650-9_5).
- Gupta, A., Watson, S. ve Yin, H. (2021). Deep learning-based aerial image segmentation with open data for disaster impact assessment. *Neurocomputing, 439*, 22-33.
- Gül, O. K. (2011). 27 Aralık 1939 Erzincan depremi'nin Sivas ve ilçelerine etkileri. *Zeitschrift für die Welt der Türken/Journal of World of Turks, 3(2)*, 135-145.
- Günbatır, M. (2008). Yön tayini probleminde en kısa yol yaklaşımı için bir web tabanlı uygulama: Muğla ili karayolları örneği. Yayınlanmamış yüksek lisans tezi, Muğla Sıtkı Koçman Üniversitesi, Muğla.
- Güner, Y., İbiş, E., Pehlivan, M. ve Ayan, G. (2019). 1970 Gediz Depremi Sonrasında

- Yapılan Çalışmaların Yönetmelik Açısından Değerlendirilmesi. VI. International Earthquake Symposium, September 25-27, Kocaeli, 18s.
- Haçın, İ. (2014). 1939 Erzincan Büyük Depremi. *Atatürk Araştırma Merkezi Dergisi*, 30(88), 37-70.
- Haddow, G. D. ve Bullock, J. A., (2004). The future of emergency management. *Journal of emergency Management*, 2(1), 19-24.
- Hanılçı, N. (2018). *Afetlerin toplum üzerindeki etkileri* [PDF belgesi]. İstanbul Üniversitesi Açık Ve Uzaktan Eğitim Fakültesi, 30 Ekim 2021 tarihinde [http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi\\_ao/afetlerintoplum%C3%BCzerindekietkileri.pdf](http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi_ao/afetlerintoplum%C3%BCzerindekietkileri.pdf) adresinden erişildi.
- Hao, X., Zhang, G. ve Ma, S. (2016). Deep learning. *International Journal of Semantic Computing*, 10(03), 417-439.
- Hidaka, A. ve Kurita, T. (2017). Consecutive dimensionality reduction by canonical correlation analysis for visualization of convolutional neural networks. In *Proceedings of the ISCIE international Symposium On Stochastic Systems Theory And Its Applications* Fukuoka, 4-5 November 2017, Japan, s. 160-167.
- İlerisoy, Z. Y., Gökşen, F., Soyuluk, A. ve Takva, Y. (2022). Deprem Kaynaklı İkincil Afetler ve Türkiye Örnekleme. *Online Journal of Art and Design*, 10(2).
- İnik Ö. ve Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- İşçi, C. (2008). Deprem nedir ve nasıl korunuruz? *Journal of Yasar University*, 3(9): 959-83.
- IFRC, 04 Ağustos 2021 tarihinde <https://www.ifrc.org/en/what-we-do/disaster-management/about-disasters/what-is-a-disaster> adresinden erişildi.
- Işın, G. (2004). Deprem: Suçlu Kim? *Başkent Üniversitesi İktisadi ve İdari Bilimler Fakültesi Eleştirel - Yaratıcı Düşünme ve Davranış Araştırmaları Laboratuvarı Editörden.-Pivolka* 3(13):15-18.
- Izadi, M., Mohammadzadeh, A. ve Haghigattalab, A. (2017). A new neuro-fuzzy approach for post-earthquake road damage assessment using GA and SVM classification from QuickBird satellite images. *Journal of the Indian Society of Remote Sensing*, 45(6), 965-977.
- Japonya Uluslararası İşbirliği Ajansı Türkiye Bürosu (JICA). (2004). *Türkiye’de doğal afetler konulu ülke strateji raporu*. Ankara.
- Jayaraman, V., Chandrasekhar, M. G. ve Rao, U. R. (1997). Managing the natural

- disasters from space technology inputs. *Acta Astronautica*, 40(2-8), 291-325.
- Kadıoğlu, M. ve Özdamar, E. (2008). Afet zararlarını azaltmanın temel ilkeleri. *JICA* 2, 4-18.
- Kadıoğlu, M. (2008). Modern, Bütünleşik Afet Yönetiminin Temel İlkeleri. *JICA Türkiye Ofisi Yayınları*, 2, 5–26.
- Kadıoğlu, M. (2011). *Afet Yönetimi beklenmeyeni beklemek en kötüsünü yönetmek*. T.C. Marmara Belediyeler Birliği Yayını: Yayın No: 65, İstanbul.
- Kale, G. B. ve Kutemate, N. B. (2011). Disaster: management tools and guidelines for effective recovery. *Journal of International Environmental Application and Science*, 6(1), 35-56.
- Kawamura, M., Tsujino K., Shimada ,T. ve Tsujiko Y. (2010). Disaster damage detection and its recovery support system of road and railroad using satellite images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*, Volume XXXVIII, Part 8, Kyoto Japan 2010.
- Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Khorrman-Manesh, A. (2017). *Handbook of Disaster and Emergency Management*. Kompendiet, ISBN 978-91-639-3200-7, Sweden, s. 34.
- Kızıloğlu, F. M., Okuroğlu, M. ve Örüng, İ. (2006). Kırsal yerleşimler ve doğal afetler. *GOÜ. Ziraat Fakültesi Dergisi*, 23(2).
- Kikin, P. M., Kolesnikov, A. A. ve Portnov, A. M. (2019). Use of machine learning techniques for rapid detection, assessment and mapping the impact of disasters on transport infrastructure. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-3/W8, GIDM 2019 – Ge oInformation for Disaster Management, 3–6 September 2019, Prague.
- Kok, J. N., Boers, E. J., Kusters, W. A., Van der Putten, P. ve Poel, M. (2009). Artificial intelligence: definition, trends, techniques, and cases. *Artificial intelligence*, 1, 270-299.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Liu, X., Li, X., Li, J. ve Wang, Q. (2013). Object-oriented remote sensing image classification and road damage adaptive extraction. In *Proceedings of*

*International Conference on Remote Sensing, Environment and Transportation Engineering (RSETE), Nanjing, China* (s. 140-143).

- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. ve Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26.
- Ma, H., Lu, N., Ge, L., Li, Q., You, X. ve Li, X. (2013). Automatic road damage detection using high-resolution satellite images and road maps. In *2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS, July 2013, Australia*, s. 3718-3721, IEEE.
- Madkour, A., Aref, W. G., Rehman, F. U., Rahman, M. A. ve Basalamah, S. (2017). A survey of shortest-path algorithms. *arXiv preprint arXiv:1705.02044*.
- Memiş, L. ve Babaoğlu, C. (2020). Afet yönetimi ve teknoloji. *Farklı Boyutlarıyla Afet Yönetimi, Ankara: Nobel*, 163-174.
- Memiş, L. ve Babaoğlu, C. (2020). Acil durum ve afet yönetiminde süreç yaklaşımı ve teknoloji. *Ömer Halisdemir Üniversitesi İktisadi ve Bilimler Fakültesi Dergisi*, 13 (4).
- Noji, E. K. (1991). Natural disasters. *Critical Care Clinics*, 7(2): 271-92. doi: 10.1016/S0749-0704(18)30306-3.
- Özdemir, H. (2016). *Afetler coğrafyası* [PDF belgesi]. İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi: 25 Temmuz 2021 tarihinde [http://auzefkitap.istanbul.edu.tr/kitap/cografya\\_lisans\\_ao/afetler\\_cografyasi.pdf](http://auzefkitap.istanbul.edu.tr/kitap/cografya_lisans_ao/afetler_cografyasi.pdf) adresinden erişildi.
- Özel, M. (2011). Afet yönetiminin iyileştirme aşaması bağlamında 2011 Van depremi sonrası "Konteyner Kent " uygulaması. *Türk İdare Dergisi*, 477: 11-34.
- Özkul, B. ve Karaman, E. (2007). Doğal Afetler İçin risk yönetimi. *TMMOB Afet Sempozyumu*, 05 - 07 Aralık 2007, Ankara, ss. 251-60.
- Özmen, B. (2000). 17 Ağustos 1999 İzmit Körfezi depremi'nin hasar durumu (Rakamsal Verileri). *Türkiye Deprem Vakfı*, 1-132.
- Özmen, B., Nurlu, M., Kuterdem, K. ve Temiz, A. (2005). Afet yönetimi ve afet işleri genel müdürlüğü. *Deprem Sempozyumu*, 23-25 Mart 2005, Kocaeli, s. 1472-1474.
- Özmen, B. (2016). *Afet yönetimi senaryo uygulamaları* [PDF belgesi]. İstanbul Üniversitesi Açık Ve Uzaktan Eğitim Fakültesi: 10 Ekim 2021 tarihinde [http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi\\_ao/ayasu.pdf](http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi_ao/ayasu.pdf) adresinden erişildi.

- Özmen, B. (2018). Afet yönetimi ve temel kavramlar. Özmen, B. (Der.), Afet yönetimi- I içinde (ss.3-26), Eskişehir, Anadolu Üniversitesi.
- Özmen, B. (2018a). Afet ve türleri. Tün, M. (Der.), Temel afet bilgisi içinde, (ss.3-25) Eskişehir, Anadolu Üniversitesi.
- Özmen, T. (2007a). *Deprem ve Antalya 'nın depremselliği*. TMMOB İnşaat Mühendisleri Odası, s. 6–12.
- Özmen, T. (2007b). Deprem Parametreleri ve tanımı. TMMOB İnşaat Mühendisleri Odası (Der.), *Deprem ve Antalya'nın Depremselliği içinde*, s. 13–20.
- Özmen, T. (2015). *Sel-Taşkın Türkiye ve Antalya*. Kutlu ve Avcı Ofset Ltd. Şti, ISBN 978-605-9156-33-2, Antalya, s. 27.
- Öztemel, E. (2003). Yapay sinir ağları. *PapatyaYayincilik*, ISBN: 978-975-6797-39-6, İstanbul, s. 16.
- Öztürk, K. (2002). Heyelanlar ve Türkiye'ye Etkileri. *G. Ü. Gazi Eğitim Fakültesi Dergisi*, 22(2): 35–50.
- Öztürk, K. ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pampal, S. (2000). Depremler, Alfa Yayını.
- Pan, S. J. ve Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- Pannu, A. (2015). Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10), 79-84.
- Rao, R. R., Eisenberg, J. ve Schmitt, T. (2007). *Improving disaster management*. National Academies Press, ISBN: 978-0-309-1096-1, Washington, 2s.
- Resmi Gazete, 18 Temmuz 2021 tarihinde  
<https://www.resmigazete.gov.tr/eskiler/2013/12/20131218-13-1.pdf> adresinden erişildi.
- Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
- Shaluf, Ibrahim M., Ahmadun, F., Said, M. A., Sharif, R. ve Mustapha, S. (2002). Technological man-made disaster precondition phase model for major accidents. *disaster. Prevention and Management: An International Journal*, 11(5):380–88. doi: 10.1108/09653560210453425.
- Shaluf, I. M. (2007). Disaster Types. *disaster prevention and management*. 16(5):704–17. doi: 10.1108/09653560710837019.

- Shinde, P. P. ve Shah, S. (2018). A review of machine learning and deep learning applications. In *2018 Fourth international conference on computing communication control and automation (ICCUBEA)*, 16-18 August. 2018, India, s. 1-6, IEEE.
- Shrestha, A. ve Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040-53065, doi: 10.1109/ACCESS.2019.2912200.
- Sucuođlu, H. (2000). The 1999 Kocaeli and Düzce-Turkey Earthquakes. *Middle East Technical University*.
- Sun, W., Bocchini, P. ve Davison, B. D. (2020). Applications of artificial intelligence for disaster management. *Natural Hazards*, 1-59.
- Sür, Ö. (1993). Türkiye'nin deprem bölgeleri. *Türkiye Coğrafyası Derg*, 2: 53-68.
- Şahin, Ş. (2019). Türkiye'de afet yönetimi ve 2023 hedefleri. *Türk Deprem Araştırma Dergisi*, 1(2): 180-96, doi: 10.46464/tdad.600455.
- Şeker, A., Diri, B. ve Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Hayriye, Ş. ve Küçükşen, M. (2019). Afet yönetimi eğitimi niçin gereklidir. *Erciyes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, XLVI (1): 193-211.
- Tamina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
- Tanırcan, G., Püskülcü, S., Necmiođlu, Ö. ve Özel, N. M. (2017). *Tsunami Bilgilendirme El kitabı, BÜ Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Afete Hazırlık Eğitim Birimi Yayınları, İstanbul*.
- Tarım ve Orman Bakanlığı Web Sitesinden: 12 Ağustos 2021 tarihinde <https://www.tarimorman.gov.tr/CEM/Belgeler/yay/202016/HEYELANLAR.pdf> adresinden erişildi.
- Taskin, B., Sezen, A., Tugsal, U. M. ve Erken, A. (2013). The aftermath of 2011 Van earthquakes: evaluation of strong motion, geotechnical and structural issues. *Bulletin of Earthquake Engineering*, 11(1), 285-312.
- Tektaş, M., Akbaş, A. ve Topuz, V. (2002). Yapay zeka tekniklerinin trafik kontrolünde kullanılması üzerine bir inceleme.
- Tercan, B. (2018). Türkiye'de Afet Politikaları ve Kentsel Dönüşüm. *Abant Kültürel Araştırmalar Dergisi*, 3(5): 102-20.

- TMMOB. (2007). *Afet Sempozyumu Bildiriler Kitabı*, Mattek Matbaacılık, ISBN: 978-9944-89-425-8, Ankara, 2s.
- TMMOB. (2010). *Türkiye’de Deprem Gerçeği ve TMMOB Makina Mühendisleri Odası’nın Önerileri. Oda Raporu.*
- TMMOB. (2012). *Türkiye’de deprem gerçeği ve TMMOB Makina Mühendisleri Odası’nın Önerileri. Oda Raporu.*
- Tuzcuoğlu, H. (2003). Yapay zeka teknikleri, depremde kullanılması ve küme kuramları. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 5(1), 73-88.
- UKEssays. (2018). Impact of Natural Disaster on Infrastructure. 22 Kasım 2021 tarihinde <https://www.ukessays.com/essays/environmental-studies/impact-natural-disaster-infrastructure-3242.php?vref=1> adresinden erişildi.
- Unlu, A., Kapucu, N. ve Sahin, B. (2010). Disaster and crisis management in Turkey : A need for a unified crisis management system. *Disaster Prevention and Management*, 10(2): 155–74, doi: 10.1108/09653561011037977.
- Ural, D. ve Özmen, B. (2014). *Onuncu Kalkınma Planı 2014-2018 Afet Yönetiminde Etkinlik Özel İhtisas Komisyan Raporu*, Ankara.
- URL-1, <https://www.medak.org.tr/faydali-bilgiler/olay-acil-durum-ve-afet/> 06 Temmuz 2021.
- URL-2, <https://www.afad.gov.tr/afet-turleri> . 4 Ağustos 2021.
- URL-3, <https://www.emdat.be/classification>. 6 Ağustos 2021.
- URL-4, <https://public.emdat.be/>. 12 Ağustos 2021.
- URL-5, <https://public.emdat.be/>. 29 Ağustos 2021.
- URL-6, <https://yillik.kizilayakademi.org.tr/2020de-turkiyede-afetler/>. 11 Ağustos 2021.
- URL-7, <https://deprem.afad.gov.tr/deprem-tehlike-haritasi>. 1 Eylül 2021.
- URL-8, <https://deprem.afad.gov.tr/depremkatalogu#> . 5 Eylül 2021.
- URL-9, <https://www.afad.gov.tr/van-depremi-hakkinda>. 5 Eylül 2021.
- URL-10, <https://www.learncomputerscienceonline.com/what-is-machine-learning/>. 12 Eylül 2021.
- Uşıkay, S. ve Aksu, S. (2002). Su kaynaklı doğal afet: taşkın. *Türkiye Mühendislik Haberleri*, (420-421–422).
- Wang, J., Qin, Q., Zhao, J., Ye, X., Feng, X., Qin, X. ve Yang, X. (2015). Knowledge-based detection and assessment of damaged roads using post-disaster high-resolution remote sensing image. *Remote Sensing*, 7(4), 4948-4967.

- Wisner, B. (2012). Earthquakes. *The Routledge Handbook of Hazards and Disaster Risk Reduction*, s. 288–99.
- Wisner, B., Gaillard, J. C. ve Kelman, I. (2012). *Handbook of Hazards and Disaster Risk Reduction*, Routledge.
- Yamaguchi, K. ve Saji, H. (2012). Analysis of road damage after a large-scale earthquake using satellite images. In *Land Surface Remote Sensing International Society for Optics and Photonics*, (Vol.8524, p. 852429).
- Yang, B., Wang, S., Zhou, Y., Wang, F., Hu, Q., Chang, Y. ve Zhao, Q. (2020). Extraction of road blockage information for the Jiuzhaigou earthquake based on a convolution neural network and very-high-resolution satellite images. *Earth Science Informatics*, 13(1), 115-127.
- Yeşilce, Y. ve Demirdağ, O. (2003). Deprem Parametreleri. *Deprem Sempozyumu, 18 Ekim 2003, Uşak*, 52s.
- Yılmaz, A. (2003). Türk Kamu Yönetimi sorun alanlarından biri olarak afet yönetimi, Pegem A Yayıncılık, ISBN 975-8792-01-6, Ankara.
- Yılmaz, A. (2017). Yapay Zeka. *Kodlab*, ISBN 978-605-9118-80-4, İstanbul ,s.s. 5-21.
- Yılmaz, İ. *Afetlerde İyileştirme Çalışmaları* [PDF belgesi]. İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi: 15 Temmuz 2021 tarihinde [http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi\\_ao/aic.pdf](http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi_ao/aic.pdf) adresinden erişildi.
- Yu, M., Yang, C. ve Li, Y. (2018). Big data in natural disaster management: A review. *Geosciences*, 8(5), 165.
- Zhang, L., Yang, F., Zhang, Y. D. ve Zhu, Y. J. (2016). Road crack detection using deep convolutional neural network. In *2016 IEEE international conference on image processing (ICIP)*, USA, (s. 3708-3712). IEEE.
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H. ve He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.

## ÖZGEÇMİŞ

2011 ile 2015 yılları arasında Cumhuriyet Anadolu Lisesinde lise öğrenimimi tamamladıktan sonra 2015 yılında Gümüşhane Üniversite Acil Yardım ve Afet Yönetimi bölümüne başladım. 2020 yılında bu bölümden mezun oldum. Lisans eğitimim sürecinde Gümüşhane Devlet Hastanesi'nde ve Kocaeli İtfaiyesi'nde staj yaptım.

