



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**BETONARME YAPILARDA YAPISAL VE
YAPISAL OLMAYAN HASARLARIN DERİN
ÖĞRENME İLE TESPİTİ**

Beyza GÜLTEKİN

YÜKSEK LİSANS TEZİ

İnşaat Mühendisliği Anabilim Dalı

Haziran-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Beyza GÜLTEKİN tarafından hazırlanan “Betonarme Yapılarda Yapısal ve Yapısal Olmayan Hasarların Derin Öğrenme İle Tespiti” adlı tez çalışması 14/06/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü İnşaat Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof.Dr. Musa Hakan ARSLAN

.....

Danışman

Dr.Öğr.Üyesi Gamze DOĞAN

.....

Üye

Dr.Öğr.Üyesi Ali Serdar ECEMİŞ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması Bilimsel Araştırma Projeleri Koordinatörlüğü (BAP) tarafından 211004036 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Beyza GÜLTEKİN

Tarih: 14/06/2022

ÖZET

YÜKSEK LİSANS TEZİ

BETONARME YAPILARDA YAPISAL VE YAPISAL OLMAYAN HASARLARIN DERİN ÖĞRENME İLE TESPİTİ

Beyza GÜLTEKİN

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr.Öğr.Üyesi Gamze DOĞAN

2022, 174 Sayfa

Jüri
Dr.Öğr.Üyesi Gamze DOĞAN
Prof.Dr. Musa Hakan ARSLAN
Dr. Öğr.Üyesi Ali Serdar ECEMİŞ

Doğal afetlerin en tehlikelisi sayılabilecek öngörülemeyen ve önlenemeyen bir doğa olayı olan depremler, tüm dünyada olduğu gibi fay hatları üzerinde bulunan ülkemizde de ciddi kayıplara sebebiyet vermiştir. Meydana gelen her depremin ardından depreme dayanıklı yapı tasarımının önemi artmakta, yapılan hasar tespit çalışmalarında yönetmeliklere uyulmadan inşa edilmiş yapılarda çok büyük olmayan depremlerde bile ciddi hasarlar olduğu gözlemlenmektedir. Depremde hasar alan tüm binalarda yapılan hasar tespit çalışmalarının doğru bir şekilde gerçekleştirilmesi büyük önem taşırken ciddi derecede hasar alan yapılarda artçı depremlerin yıkım tehlikesi dolayısıyla çalışmaların aynı zamanda hızlı ve pratik olması da son derece önemlidir. Uzman kişi sayısının sınırlı olması ve deprem sırasında hasar alan yapı sayısının çok fazla olması hasar tespit çalışmalarının yetersiz kalmasına neden olmaktadır. Bu durumda can ve mal kayıplarının artmasına neden olabilecek şekilde bilinçsizce hasarlı yapılarda yaşanmaya devam edilmektedir. Deprem sonrası yapılan hasar tespit çalışmalarında verilen önemli kararlardan biri betonarme yapılar özelinde oluşan çatlakların yapısal elemanda veya yapısal olmayan elemanda bulunmasına göre ayrımının yapılmasıdır. Yapısal elemanlarda özellikle kolon ve perdelerde oluşan deprem hasarları yapının önemli derecede hasar aldığını gösterirken yapısal olmayan elemanlarda oluşan deprem hasarları yapının kullanım durumunu önemli ölçüde etkilememektedir. Bu tez çalışmasında uzman kişilere hasar tespit çalışmaları sırasında yardımcı olabilecek, kararların doğru ve hızlı şekilde verilmesini sağlayacak bir yapay zekâ algoritması geliştirilmiştir. Çalışmada yapay zekânın alt dallarından biri olan verilerden kendi kendine öğrenerek farklı veriler üzerinde tahmin yapabilen Derin Öğrenme modeli tercih edilmiştir. Bu tez çalışmasının amacı, hasar görüntülerini yapısal elemanda oluşan hasar ya da yapısal olmayan elemanda oluşan hasar şeklinde sınıflandırmak olduğu için bu alanda oldukça başarılı çalışmalarda kullanılmış Evrişimli Sinir Ağları modelinden yararlanılmıştır. Son yıllarda ülkemizde meydana gelen $M_w \geq 5$ büyüklüğüne sahip İstanbul (Silivri), Elazığ (Sivrice) ve İzmir (Seferihisar) depremleri sonrası yapılan hasar tespit çalışmalarından elde edilen hasar görüntüleri algoritma geliştirmek üzere toplanmıştır. Optimum değerler seçilerek geliştirilen model, betonarme yapılarda oluşan yapısal ve yapısal olmayan eleman hasarlarını %93,13 oranında başarı ile tespit edip sınıflandırmıştır. İnşaat mühendisliği alanında henüz çok yeni olan Derin Öğrenme sistemlerinin geliştirilerek kullanılabileceğinin yanında bu çalışmada geliştirilen modelin hasar tespit çalışmalarında uzman kişilere yardımcı olabileceği kanıtlanmıştır.

Anahtar Kelimeler: Betonarme yapılar, deprem hasarları, Derin Öğrenme, Evrişimli Sinir Ağları, hasar tespit, yapısal eleman hasarları, yapısal olmayan eleman hasarları.

ABSTRACT

MS THESIS

DETECTION OF STRUCTURAL AND NON-STRUCTURAL DAMAGES IN REINFORCED CONCRETE STRUCTURES WITH DEEP LEARNING

Beyza GÜLTEKİN

**Konya Technical University
Institute of Graduate Studies
Department of Civil Engineering**

Advisor: Asst.Prof.Dr. Gamze DOĞAN

2022, 174 Pages

Jury

**Asst.Prof.Dr. Gamze DOĞAN
Prof.Dr. Musa Hakan ARSLAN
Asst.Prof.Dr. Ali Serdar ECEMİŞ**

Earthquakes, an unpredictable and unpreventable natural event that can be considered the most dangerous of natural disasters, have caused serious losses in our country, which is located on fault lines, as in the whole world. After each earthquake that occurs, the importance of earthquake-resistant building design increases, and it is observed that serious damages occur in structures built without complying with the regulations in damage assessment studies, even in small earthquakes. While it is of great importance that the damage assessment studies carried out in all buildings damaged in the earthquake are carried out correctly, it is extremely important that the works are also fast and practical due to the danger of destruction of aftershocks in seriously damaged buildings. The limited number of experts and the large number of buildings damaged during the earthquake cause the damage assessment studies to be insufficient. In this case, people continue to live in damaged buildings unconsciously, which may lead to increased loss of life and property. One of the important decisions made in the damage assessment studies made after the earthquake is to differentiate the cracks that occur in reinforced concrete structures according to whether they are in the structural element or the non-structural element. Earthquake damages on structural elements, especially on columns and shear walls, show that the structure has been damaged significantly, while earthquake damages on non-structural elements do not significantly affect the use of the building. In this thesis, an artificial intelligence algorithm has been developed that can help experts during damage assessment studies and ensure that decisions are made accurately and quickly. In the study, the Deep Learning model, which is one of the sub-branches of artificial intelligence, which can make predictions on different data by learning by itself from the data, was preferred. Since the aim of this thesis study is to classify the damage images as damage to the structural element or damage to the non-structural element, the Convolutional Neural Networks model, which has been used in very successful studies in this field, has been utilized. The damage images obtained from the damage assessment studies carried out after the Istanbul (Silivri), Elazığ (Sivrice) and İzmir (Seferihisar) earthquakes with a magnitude of $M_w \geq 5$ that occurred in our country in recent years were collected to develop an algorithm. The model, which was developed by selecting the optimum values, detected and classified the structural and non-structural element damages in reinforced concrete structures with a success rate of 93.13%. In addition to the fact that Deep Learning systems, which are still very new in the field of civil engineering, can be developed and used, it has been proven that the model developed in this study can help experts in damage assessment studies.

Keywords: Convolutional Neural Networks, damage detection, Deep Learning, earthquake damages, non-structural element damages, reinforced concrete structures, structural element damages.

ÖNSÖZ

Bu tez çalışmasında deprem sonrasında betonarme binalarda oluşan hasarların tespitinde mühendislere yardımcı olabilecek yapısal eleman hasarlarını yapısal olmayan eleman hasarından ayıran bir sistem geliştirilmiştir. Fay hatları üzerinde bulunan ülkemizde depremlerin ardından verilen can ve mal kayıpları göz önünde bulundurulduğunda bu çalışma insan hayatına doğrudan katkı sunmaktadır.

Bu tez çalışmasına maddi destek sunan Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkür ederim. Tez çalışmamın bütün aşamalarında ilgisini, desteğini ve tecrübelerini benden esirgemeyen; çalışmalarındaki titizliğini ve başarılarını kendime örnek aldığım danışman hocam Sayın Dr.Öğr.Üyesi Gamze DOĞAN'a; tüm eğitim hayatım boyunca beni her zaman destekleyen, çalışmalarımı büyük ilgi ve merakla takip eden sevgili aileme sonsuz teşekkürler.

Beyza GÜLTEKİN
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ.....	1
1.1. Tezin Amacı	2
1.2. Tezin Önemi	2
1.3. Tezin Kapsamı.....	3
2. KAYNAK ARAŞTIRMASI	5
2.1. Yapı Mühendisliğinde Derin Öğrenme Çalışmaları	5
2.2. Betonarme Binalarda Oluşan Deprem Hasarları ile İlgili Çalışmalar	9
3. YAPAY ZEKÂ VE DERİN ÖĞRENME.....	12
3.1. Derin Sinir Ağları	17
3.1.1. Tekrarlayan Sinir Ağları (TSA)	17
3.1.2. Uzun Kısa Süreli Hafıza Ağları (UKSHA)	18
3.1.3. Sınırlı Boltzmann Makineleri (SBM)	19
3.1.4. Derin İnanç Ağları (DİA)	19
3.1.5. Derin Oto-Kodlayıcılar (DOK).....	20
3.1.6. Evrişimli Sinir Ağları (ESA)	21
3.2. Derin Sinir Ağlarında Kullanılan Parametreler	32
3.2.1. Döngü (Epoch).....	33
3.2.2. Erken durdurma (Early stopping)	33
3.2.3. Veri boyutu	33
3.2.4. Öğrenme hızı	34
3.2.5. Yığın boyutu (Batch size).....	34
3.2.6. Ağırlık (Weight)	35
3.2.7. Seyreltme değeri	35
3.2.8. Bias değeri	35
3.2.9. Optimizasyon fonksiyonları	36
3.2.10. Kayıp (Loss) Fonksiyonu	38
3.2.11. Az Öğrenme (Underfit) ve Ezberleme (Overfit) Durumları.....	39
3.2.12. Veri Artırma (Data Augmentation)	41
3.2.13. Isı Haritaları (Heatmap).....	42
3.3. Transfer Öğrenme	43
3.3.1. AlexNet	44
3.3.2. ZFNet	45
3.3.3. VGGNet.....	45

3.3.4. GoogLeNet	47
3.3.5. ResNet	48
3.4. Python ve Uygulama Kütüphaneleri.....	50
4. DEPREM VE BETONARME YAPI HASARLARI	53
4.1. Deprem Sonrası Betonarme Binalarda Oluşan Hasarlar.....	56
4.2. Betonarme Yapı Elemanlarının Deprem Davranışları.....	64
4.2.1. Kolon hasarları.....	65
4.2.2. Perde hasarları	71
4.2.3. Kiriş hasarları	73
4.3. Yapısal Olmayan Elemanların Deprem Davranışı	76
4.3.1. Sıva çatlakları	76
4.3.2. Duvar çatlakları.....	79
5. ANALİTİK ÇALIŞMA	85
5.1. Ülkemizde Yaşanan Son Depremler ve Oluşan Hasarların İncelenmesi.....	85
5.1.1. İstanbul (Silivri) Depremi	85
5.1.2. Elazığ (Sivrice) Depremi.....	93
5.1.3. İzmir (Seferihisar) Depremi	112
5.2. Verilerin İstatistikleri.....	132
5.2.1. Veri artırma işleminin uygulanması.....	134
5.2.2. Verilerin dağılımı.....	135
5.3. Derin Öğrenme Algoritmasının Geliştirilmesi	138
6. SONUÇLAR VE ÖNERİLER	161
KAYNAKLAR	164
ÖZGEÇMİŞ.....	174

SİMGELER VE KISALTMALAR

Simgeler

M_w	: Deprem Magnitüdü (Moment büyüklüğü)
R_{epi}	: Deprem merkezine olan uzaklık (km)

Kısaltmalar

AdaDelta	: Adaptive Delta
AdaGrad	: Adaptive Gradient
Adam	: Adaptive Momentum
AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
AlexNet	: Alex Network
CPU	: Central Processing Unit
DB	: Doğu-Batı
DD-2:	: 50 yılda aşılma olasılığı %50, tekrarlanma periyodu 475 yıl, deprem yer hareketi niteliği seyrek olan deprem yer hareketi düzeyi
DD-3:	: 50 yılda aşılma olasılığı %10, tekrarlanma periyodu 72 yıl, deprem yer hareketi niteliği sık olan deprem yer hareketi düzeyi
DÖ	: Derin Öğrenme
ESA	: Evrişimli Sinir Ağları
Gİ	: Görüntü İşleme
GoogLeNet	: Google Network
GÖ	: Göçme Önlenmesi
GPU	: Graphics Processing Unit
ImageNet	: Image Network
KG	: Kuzey-Güney
KH	: Kontrollü Hasar
KRDAE	: Kandilli Rasathanesi Deprem Araştırma Enstitüsü
LeNet	: LeCun Network
MÖ	: Makine Öğrenmesi
PGA	: Peak Ground Acceleration
ReLU	: Rectified Lineer Unit
ResNet	: Residual Network
RMSProp	: Root Mean Square Error Propability
SBM	: Sınırlı Boltzmann Makineleri
SGD	: Stochastic Gradient Descent
SH	: Sınırlı Hasar
TBDY - 2018	: 2018 Türkiye Bina Deprem Yönetmeliği
TDK	: Türk Dil Kurumu
TDY – 2007	: 2007 Türkiye Deprem Yönetmeliği
TSA	: Tekrarlayan Sinir Ağları
UKSHA	: Uzun Kısa Süreli Hafıza Ağları
VGGNet	: Visual Geometry Group Network
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ
ZFNet	: Zeiler and Fergus Network

1. GİRİŞ

Dünya üzerinde meydana gelen doğal afetler içerisinde en yıkıcı olanı depremdir. Çeşitli nedenlerden (tektonik, volkanik, çöküntü) dolayı oluşan depremler, ciddi derecede can ve mal kayıplarına sebebiyet vermektedir. Ülkemizde aktif şekilde üç fay hattı bulunmaktadır. Özellikle nüfusumuzun fay hatları üzerinde bulunan şehirlerinde yaşayan yaklaşık %95'lik bir kısmı her beş yılda bir yıkıcı depremlerle karşı karşıya kalmaktadır. Depremlerin minimum hasarlarla atlatılması için ilk yapılması gereken yönetmelikler ışığında depreme dayanıklı bina tasarımına önem vererek binaları tasarlamaktır. Ancak ülkemizde birçok yerleşim yerinde bulunan binaların neredeyse yarısı yapı denetim kavramının olmadığı veya gerekli önemin verilmediği zaman dilimlerinde inşa edildiğinden söz konusu yönetmeliklere tamamen uyularak tasarlandıkları söylenememektedir. Bu nedenle meydana gelen aslında çok şiddetli olmayan depremlerde bile ciddi derecede hasar alan birçok bina bulunmaktadır. Söz konusu binaların hasar dereceleri ve kullanım durumları hakkında yorum yapmak amacıyla depremlerin ardından hasar tespit çalışmaları gerçekleştirilmektedir. Bu çalışmaların mümkün olduğunca hızlı, pratik ve doğru şekilde yapılması gerekmektedir. İnsanların evlerine ve işyerlerine güvenle geri dönebilmeleri için oldukça büyük önem arz eden bu çalışmalar, depremde hasar alan bina sayısının fazla olması ve yeterli donanımına sahip uzman kişi sayısının kısıtlı olması gibi nedenlerle hızlı bir şekilde yapılamamaktadır. Yetkin kişilerin henüz ulaşamadığı binalarda uzman olmayan kişiler tarafından verilen yanlış kararlar, deprem hasarlı yapılarda insanların bulunması sebebiyle can güvenliği problemi oluşturabilmektedir. Bunun yanında tespit yapan çalışanların binalara girip çıkması tehlikeli sonuçlar da doğurabilmektedir. Ayrıca taşıyıcı sisteminde hasar oluşmamış binalar için yıkım kararları verilmesi de ekonomik kayıplara sebebiyet verebilmektedir. Tüm bu nedenler göz önüne alındığında deprem sonrası yapılan hasar tespit çalışmalarının otomatikleştirilmesi için uzman bir sistem oluşturulması doğru ve pratik kararlar alınmasını sağlayacaktır.

Çeşitli mühendislik alanlarında meydana gelen problemleri çözmek amacıyla akıllı sistemler kullanılmaktadır. Söz konusu sistemler, araştırmacılara hem zaman hem de ekonomik anlamda avantaj sağlamaktadır. Pek çok sahada kullanım alanına sahip olan Yapay Zekâ (YZ) sistemleri, inşaat mühendisliği alanında da kendisine yer edinmeye başlamıştır. Bu tez çalışmasında, hasar tespit çalışmalarını otomatikleştirmek amacıyla bu sistemlerin kullanılması önerilmiştir.

1.1. Tezin Amacı

Depremlerin ardından yapılan hasar tespit çalışmalarında uzman kişiler, yapıların kullanım durumları hakkında önemli kararlar vermektedir. Söz konusu bu kararlar verilirken hasar almış binalara girerek özellikle yapı taşıyıcı sistemlerinde meydana gelen hasarlar incelenmektedir. Hasar tespit sürecinde en önemli ayrımlardan biri yapısal ve yapısal olmayan elemanlardaki hasar oluşum şekillerinin tespit edilmesidir. Yapısal elemanlarda oluşan hasarlar binanın depremden ciddi derecede etkilendiğini gösterirken, yapısal olmayan elemanlarda oluşan hasarlar büyük bir tehlike arz etmemektedir. Hasar tespit çalışmaları yapılırken verilecek yanlış bir karar, ekonomik kayıplara ve hatta can kayıplarına bile yol açabilmektedir. Tüm bu nedenlerden dolayı hasar tespit çalışması yapan yetkilileri destekleyen ve zaman anlamında pratiklik sağlayan uzman bir sistem bu çalışma kapsamında önerilmiştir.

Bu tez çalışmasının amacı, deprem sonrası betonarme binalarda meydana gelen yapısal ve yapısal olmayan hasarları hızlı ve doğru bir şekilde ayırt edebilen uzman bir sistem geliştirmektir. Bu amaç doğrultusunda, bir YZ modeli olan Derin Öğrenme (DÖ) algoritması kullanılmış ve yapılan analitik çalışma neticesinde hasar türlerini ayırt edebilen bir model geliştirilmiştir.

1.2. Tezin Önemi

Deprem, ülkemiz için kaçınılmaz bir gerçektir. Fay hatları üzerinde bulunan şehirlerin kalabalık nüfusu ve bu yerleşim yerlerinin çok eski olması burada inşa edilen betonarme yapıların hızlı ve kuralsız şekilde yapılmasına neden olmuştur. Deprem bölgelerinde inşa edilen bu yapılar, aslında hiç de yıkıcı büyüklüğe sahip olmayan depremlerde ciddi hasarlar almakta ve hatta göçmektedir. Depremlerden sonra hasar alan binalar hakkında karar vermek, can ve mal kayıplarını minimuma indirmek amacıyla yapılan en önemli çalışmalardan biri hasar tespit çalışmalarıdır. İnsanlar depremlerden belirli bir süre sonra evlerine girme eğilimi gösterebilmektedir. Ancak bu durum ciddi hasar almış binalarda artçı şokların etkisiyle tehlikeli durumlar oluşturabilmektedir. Alanında uzman kişilerin ulaşamadığı binalarda değerlendirme yapılamaması da uzman olmayan kişilerin yanlış kararların alınmasına aracılık etmesi gibi çeşitli sorunlara sebebiyet verebilmektedir. Örneğin yapısal olmayan elemanda oluşmuş bir hasarın

yapısal eleman hasarı olarak yorumlanması ekonomik sorunlara yol açabilir. Bunun yanında yapısal elemanda oluşmuş bir hasarın yapısal olmayan elemanda oluşan hasar şeklinde yorumlanması ise can ve mal kayıplarına sebebiyet verebilmektedir. Tüm bu nedenlerle yapılan hasar tespit çalışmalarında bir betonarme binada meydana gelen deprem hasarlarını yapısal ve yapısal olmayan elemanda oluşan hasar şeklinde ayırmak ciddi derecede önemlidir. Kolonda veya perdede oluşan çatlaklar binanın önemli derecede hasar aldığını gösterirken, dolgu duvarda meydana gelen hasarlar onarılabilmekte ve binanın kullanımını etkilememektedir. Tüm bu yorumları yapmak, yanlış kararların önüne geçmek, tehlikeli uygulamalardan kaçınmak amaçlarıyla hasar tespit çalışmalarını otomatikleştirmek, yapısal ve yapısal olmayan elemanlarda oluşan hasarları birbirinden ayırmak için bu çalışmada uzman bir sistem geliştirilmiştir. Geliştirilen bu sistem, taşıyıcı sisteminde hasar oluşmamış yapılar için verilen hem ekonomik kayıplara hem de insanların barınma problemi ile karşı karşıya kalmasına neden olabilecek yıkım kararlarının önüne geçilmesini sağlayacaktır. Bunun yanında taşıyıcı sistemlerinden hasar alan yapıların içerisinde insanların konaklamaya devam etmesi tehlikesini ortadan kaldırarak can ve mal kayıplarının minimum düzeyde tutulmasına yardımcı olacaktır.

YZ sistemlerinden biri olan DÖ modeli son yıllarda neredeyse tüm sektörlerde sıklıkla tercih edilen bir algoritmadır. İnşaat mühendisliği alanında DÖ özelinde yapılmış çalışmalar incelendiğinde son beş yıldır bu alana yönelim olduğu ve geliştirilmeye açık bir alan olduğu görülmektedir. Bu tez çalışması DÖ algoritmaları ile inşaat mühendisliği alanındaki hasar tespit çalışmalarını harmanladığından alanında öncü çalışmalardan biri olacaktır. Ayrıca bu tez çalışmasında geliştirilen algoritma için veri olarak toparlanan hasar görüntüleri ülkemizde meydana gelen depremler sonrasında betonarme yapı stoğunda yapılan saha çalışmalarında elde edilmiştir. Bu nedenle daha önce üzerinde çalışılmamış yeni bir veri setinin oluşturulması çalışmanın özgünlüğü açısından oldukça değerlidir.

1.3. Tezin Kapsamı

Makinelerin insan beynini taklit edip kendi kendine düşünebilmesi olarak tanımlanabilen YZ sistemleri tüm dünyayı etkisi altına almış, sağladığı avantajlarıyla her alanda tercih edilmeye başlanmıştır. Hızla gelişen teknolojinin en popüler ürünlerinden biri olan YZ sistemleri, inşaat mühendisliği alanında henüz yeni olarak nitelendirilebilmektedir. Çalışma kapsamında depremlerin sonrasında yapılan hasar tespit

çalışmalarını DÖ modellerine öğreterek hasar sınıflandırması yapabilen otomatik uzman bir sistem oluşturmak amaçlanmıştır. Çeşitli alt dallara sahip olan DÖ modellerinden görüntüler üzerinden işlem yapmak için Evrişimli Sinir Ağları (ESA) tercih edilmektedir. Yapılan çalışma görüntü sınıflandırma işlemi olduğundan çalışmada ESA modeli kullanılmıştır. Geniş bir literatür araştırmasından sonra YZ sistemlerinin yakıtı olarak nitelendirilen veri toplama aşamasına geçilmiş, ülkemizde son yıllarda meydana gelen $M_w \geq 5$ büyüklüğündeki İstanbul (Silivri), Elazığ (Sivrice) ve İzmir (Seferihisar) depremleri sırasında betonarme yapılarda oluşan hasar görüntüleri Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın "hasartespit.csb.gov.tr" adresinden ve Doğan ve ark. (2020) tarafından yapılan saha çalışmasından elde edilmiştir. Algoritma söz konusu verilerle eğitilmiş ve test edilmiş, sonucunda algoritmanın yeni karşılaştığı görüntüler üzerinden yaptığı tahmin değerlerinin doğruluk oranı, modelin kullanılabilir olduğunu kanıtlamıştır.

Derin sinir ağlarının çeşitleri ve özellikle çalışmada kullanılan ESA Bölüm 3'te ayrıntılı şekilde açıklanmıştır. Daha sonra Bölüm 4'te genel olarak depremlerden bahsedilmiş ve betonarme yapılarda depremler sırasında oluşabilecek hasarlar anlatılmıştır. Güncel depremler ile bu depremler sırasında oluşan hasarların istatistikleri ve analitik çalışma Bölüm 5'te işlenmiş, son olarak 6. Bölümde elde edilen sonuçlara yer verilmiştir.

2. KAYNAK ARAŞTIRMASI

2.1. Yapı Mühendisliğinde Derin Öğrenme Çalışmaları

Abdeljaber ve ark (2018), DÖ modellerinden ESA'yı sismik tabanlı yapı hasarlarının tespiti için kullanmışlardır. Bu çalışma, yapı sağlığı izleme üzerine bir problem için deneysel veriler kullanılarak doğrulanmış, ESA tabanlı yaklaşımın hasar seviyesini başarıyla tahmin ettiği görülmüştür.

Akan ve ark (2020), YZ'yi depreme dayanıklı mimari yapı tasarımında kullanarak, Gİ ve DÖ yöntemlerini beraber kullanmış düzensiz taşıyıcı sistem tespiti yapmayı amaçlamışlardır. Çalışmada araştırmacılar mimari tasarım sırasında mimarlara taşıyıcı sistem ve deprem mimarlığı hakkında bilgi verecek bir Düzensizlik Kontrol Asistanı yapmışlardır. Sonuç olarak, insanın öğrenme mekanizmasını taklit edebilen bu asistanın taşıyıcı sistem düzensizlikleri hakkında tutarlı ve doğru yorum yapabildiği sonucuna ulaşmışlardır.

Atha ve Jahanshahi (2018) çalışmalarında, metalik yüzeylerde korozyon tespiti için ESA'ya dayalı DÖ yaklaşımlarını kullanmışlardır. Korozyon, yapısal sistemlerde önemli bir ekonomik etkiye sahip olan ve gözetim altında olmazsa güvenlik riskleri oluşturabilen önemli bir kusurdur. Çalışmada önerilen ESA modelinin önemli ölçüde yüksek bir başarı ile korozyonu algıladığı görülmüştür.

Avcı ve ark (2017), yapısal hasar tespiti için DÖ üzerine bir çalışma yapmıştır. Çalışmada ESA kullanılmıştır. Önerilen yöntem, hasara bağlı özellikleri otomatik olarak çıkarabilmekte ve gerçek zamanlı hasar tespiti için kullanılmasına olanak sağlamaktadır. Çalışmada ayrıca çelik çerçeve üzerinde deneysel bir çalışma yapılmış, deneysel sonuçlar, önerilen algoritmanın geleneksel Makine Öğrenmesi (MÖ) tabanlı hasar tespit yöntemlerine bir alternatif olarak çok umut verici olduğunu göstermiştir.

Cha ve ark. 2018 yılında; orta seviyeli beton çatlağı, yüksek seviyeli beton çatlağı, çelik korozyonu, cıvata korozyonu ve çelik delaminasyonu olmak üzere beş farklı hasar türünü tespit etmek amacıyla DÖ modeli oluşturmuşlardır. Sırasıyla %90,6; %83,4; %82,1; %98,1; %84,7 oranlarında tahmin başarıları elde edilmiştir.

Cha ve Choi (2017), DÖ modellerinden ESA'yı kullanarak yapılarındaki çatlak hasarları tespiti üzerine bir çalışma yapmıştır. Çalışmada ESA, 256×256 piksel çözünürlükte 40.000 görüntü üzerinde eğitilmiş ve sonuç olarak yaklaşık %98 doğrulukla eğitim yapmıştır. Önerilen yaklaşımın doğruluğu ve uyarlanabilirliği, çeşitli koşullar

altında farklı bir yapıdan alınan $5,888 \times 3,584$ piksel çözünürlüklü 55 görüntü üzerinde test edilmiştir. Sonuçlar, söz konusu yöntemin oldukça iyi performans gösterdiğini ve gerçekçi durumlarda somut çatlaklar bulabileceğini göstermiştir.

Çakıroğlu ve Süzen, 2020 yılında yaptıkları derleme çalışmalarında DÖ'nün inşaat mühendisliği alanında kullanımını ve elde edilen sonuçları araştırmıştır. Ele aldıkları çalışmalarda yüksek oranda başarı elde edildiğine, bu alanda yapılan çalışmaların artması gerektiğine değinmişlerdir.

Feng ve ark., 2019 yılında yaptıkları çalışmalarında, hidroelektrik santrallerinde oluşan hasarları görüntüler üzerinden sınıflandırmak amacıyla DÖ modeli kullanmışlardır. Hasar görüntüleri beton çatlağı, sızıntı, parçalanma, donatı açığa çıkması ve hasar yok olmak üzere beş sınıfa ayrılmıştır. Sonuçta modelden %96,8 oranında başarı yakalanmıştır.

Gao ve Mosallam 2018 yılındaki çalışmalarında otomatik hasar tespiti için DÖ yöntemini tercih etmişlerdir. Çalışmada görüntüler kolon/kiriş ya da duvar olmak üzere ikili şekilde sınıflandırılmış; betonda dökülme var ya da yok olmak üzere yine ikili şekilde sınıflandırılmış; hasar yok, az hasar ya da orta/ağır hasar olmak üzere üçlü şekilde sınıflandırılmış ve son olarak hasar yok, eğilme hasarı, kesme hasarı ya da bileşik (eğilme ve kesme) hasar olmak üzere dördü sınıflandırılmıştır. İkili sınıflandırmalarda %90'ın üzerinde başarı yakalanırken üçlü sınıflandırmada %89,7, dördü sınıflandırmada %68 oranında başarı elde edilmiştir.

Hoskere vd., 2018 yılında görüntüler üzerinden hasar tespit çalışması yapmak için DÖ yöntemine başvurmuşlardır. Çalışma kapsamında üç farklı model oluşturulmuş, bunlardan birincisinde görüntüde bulunan farklı nesneler algılanıp sonucu etkilemesi önlenmiştir. İkincisinde hasar var ya da yok ayrımı yapılmış, sonuncusunda ise hasar türünü betonda çatlak, beton dökülmesi ve donatı açığa çıkması olarak üç sınıfa ayırma işlemi gerçekleştirilmiştir. Çalışma sonucunda ilk modelden %88,8; diğer iki modelden %91,1 sınıflandırma başarısı elde edilmiştir.

Kiriş (2021) çalışmasında, deprem gibi yıkıcı doğal afetler sonucu ağır hasar almış binaların otomatik şekilde tespit edilmesi amacıyla DÖ yöntemlerinden ESA'yı kullanarak bir model oluşturmuştur. Hasarlı ve normal binalar olmak üzere görüntüleri iki ayrı sınıfa ayırma işlemi için tasarlanan algorithmadan %90 oranında bir başarı elde edilirken; aynı görüntüleri hasarlı binalar, az hasarlı binalar ve hasarsız binalar olmak üzere üç sınıfa ayırma işlemi için tasarlanan algorithmadan %69 oranında başarı elde edilmiştir.

Lin ve Nie (2017) çalışmalarında, yapısal hasar tespitini DÖ modellerinden biri olan ESA yoluyla yapan otomatik hasar çıkarma yöntemini geliştirmiştir. Çalışmada ESA ağının yapısal hasarları belirlemede olumlu sonuçlar verdiği gözlemlenmiştir.

Mangalathu ve Burton (2019), depremde etkilenen binaların DÖ'ye dayalı bir yöntemle sınıflandırılması üzerine çalışmışlardır. Çalışmada 2014 yılında Kaliforniya'da meydana gelen deprem sonucu 3423 binada meydana gelen hasarlardan oluşan veri seti rastgele olarak eğitim ve test alt kümelerine ayrılmıştır. Eğitim seti kullanılarak tahmine dayalı bir model oluşturulmuş ve bu modelin performansı test seti ile değerlendirilmiş % 86 genel doğruluk başarısı elde edilmiştir.

Mondal vd. 2019 yılında yaptıkları çalışmalarında Erzincan (1992), Düzce (1999), Bingöl (2003), Peru (2007), Wenchuan (2008), Haiti (2010), Nepal (2015), Tayvan (2016) ve Ekvador (2016) depremlerinin ardından betonarme binalarda oluşan hasarları sınıflandırmayı amaçlamışlardır. DÖ modellerinden yararlanılarak görüntüleri betonda çatlama, dökülme, donatı açığa çıkması ve donatı burkulması olmak üzere dört sınıfa ayırmışlardır. Çalışmada Inception v2, ResNet-50, ResNet-101, Inception ResNet v2 mimarileri ile farklı modeller oluşturulmuş ve elde edilen başarılar kıyaslanmıştır. Inception v2 mimarisinden %51, ResNet-50 mimarisinden %54, ResNet-101 mimarisinden %55 ve Inception ResNet v2 mimarisinden %61 oranlarında başarı elde edilmiştir.

Nahata vd. 2019'da 2010 Haiti depremi, 2015 Nepal depremi, 2016 Tayvan depremi ve 2016 Ekvador depremleri sırasında oluşmuş hasarların görüntülerini hasar yok, az hasar, büyük hasar ve çökme şeklinde dört sınıfa ayırmak için bir çalışma yapmışlardır. DÖ yöntemi kullanılarak yapılmış bu çalışmada 0,00001; 0,0003; 0,0001 olmak üzere üç farklı öğrenme oranı kullanılmıştır. Sonucunda %92'lik bir oranla en yüksek başarı 0,00001 öğrenme oranının kullanıldığı algorithmadan elde edilmiştir.

Pathirage ve ark. (2018), otomatik kodlayıcı sinir ağlarına ve DÖ'ye dayalı çelik yapılarda hasar tespiti üzerine bir çalışma yapmıştır. Bu çalışmada, doğal frekanslar ve mod şekilleri gibi titreşim özellikleri algoritma için giriş parametreleri olarak kullanılmış ve yapısal hasarlar çıkış vektörü olarak belirlenmiştir. Çelik çerçeve yapıları üzerinde yapılan sayısal ve deneysel araştırmalar, geleneksel Yapay Sinir Ağları (YSA) yöntemleriyle karşılaştırıldığında önerilen DÖ yönteminin doğruluğunun ve verimliliğinin çok daha yüksek olduğu kanıtlanmıştır.

Patterson vd. 2018 yılında sismik hasarları tespit etmek amacıyla yaptıkları çalışmalarında, DÖ yöntemini kullanmayı tercih etmişlerdir. Yazarlar, tek bir görüntü

üzerinden birden fazla hasar türünü ve meydana geldikleri yapısal üyeyi tespit etmesi için bir algoritma geliştirmişlerdir. Çalışma kapsamında üç farklı model oluşturulmuştur. Bunlardan ilki görüntü üzerinden hasar var veya yok çıkarımı yapan algoritma, ikincisi görüntü üzerindeki hasarın yerini tespit edip etrafına sınırlayıcı dikdörtgen çizen algoritma ve sonuncusu sadece kısa kolonlarda meydana gelen kesme hasarlarını görüntü üzerinden tespit edip dikdörtgen sınırlayıcı içerisine alan algoritmadır. İlk modelde %88,3; ikinci modelde %85 ve üçüncü modelde %77 başarı oranı yakalanmıştır.

Xu vd. 2018'de yaptıkları hasar tespit çalışmasını sadece betonarme kolonlar ile sınırlamıştır. DÖ yöntemini kullanarak bir görüntü üzerinde birden fazla hasarı (beton çatlağı, beton dökülmesi, donatı açığa çıkması ve donatı burkulması) tespit edebilmek için yola çıkan yazarlar, beton çatlaklarında %86,7; beton dökülmelerinde %89,9; donatı açığa çıkmasında ve donatı burkulmasında %94,4 oranlarında başarı elde etmişlerdir.

Yaseen ve ark (2018), çalışmalarında kiriş-kolon bölgesi kesme tahminini DÖ yoluyla yapmışlardır. Çalışma için literatürde son yirmi yılda yapılan deneysel veriler toparlanmış, deneysel sonuçlar ile geliştirilen model sonuçlarının tahmin değerleri arasında kabul edilebilir bir uyum olduğu gözlemlenmiştir.

Çizelge 2.1'de yapı mühendisliği alanında DÖ yöntemi kullanılarak yapılmış çalışmalar listelenmiştir.

Çizelge 2.1. Yapı mühendisliğinde DÖ çalışmaları

Uygulama	Referans	Teknoloji
Yapısal hasar tespiti	Abdeljaber ve ark. (2018)	DÖ
	Avcı ve ark. (2017)	DÖ
	Feng ve ark. (2019)	DÖ
	Gao ve Mosallam (2018)	DÖ
	Hoskere ve ark. (2018)	DÖ
	Kiriş (2021)	DÖ
	Lin ve Nie (2017)	DÖ
	Mondal ve ark. (2019)	DÖ
	Nahata ve ark. (2019)	DÖ
	Patterson ve ark. (2018)	DÖ
	Xu ve ark (2018)	DÖ
	Pathirage ve ark. (2018)	DÖ

Düzensiz taşıyıcı sistem tespiti	Akan ve ark. (2020)	DÖ
Korozyon tespiti	Atha ve Jahanshahi (2018)	DÖ
Çoklu hasar tespiti	Cha ve ark (2018)	DÖ
Çatlak tespiti	Cha ve Choi (2017)	DÖ
Kolon-kiriş birleşim bölgesi kesme tahmini	Yaseen ve ark. (2018)	DÖ

2.2. Betonarme Binalarda Oluşan Deprem Hasarları ile İlgili Çalışmalar

Arslan ve Korkmaz 2007 yılında yaptıkları çalışmalarında, depremlerden sonra betonarme binalarda gözlemlenen hasarlar üzerinde durmuşlardır. Çalışma kapsamında güçlü kiriş-zayıf kolon, yumuşak kat, kötü detaylandırma uygulamaları gibi çeşitli sorunlar incelenmiştir. Çalışma sonucunda, hasar seviyelerinin kontrollü düzeyde kalması için sünek tasarımların yapılması; beton kalitesini düşüren deniz suyu, uygun olmayan su/çimento oranı, yetersiz granülometri gibi uygulamalardan kaçınılması; kanca ve etriye kullanımının artırılması; bitişik nizam, kısa kolon, yumuşak ve zayıf kat, ağır çıkmalar, simetrik olmayan binalardan kaçınılması gerektiği vurgulanmıştır.

Coza 2003 yılında yaptığı çalışmada, betonarme binalarda deprem sırasında meydana gelen hasarları ve nedenlerini incelemiştir. Oluşan hasarların nedenlerini tasarım ve yapım aşamasında yapılan hatalar olmak üzere iki ayrı başlık altında toplamış, çalışmanın yapıldığı yıl yürürlükte olan yönetmeliklerin sınır koşulları ayrıntılı şekilde irdelenmiştir. Çalışmanın sonucunda ciddi derecede deprem bölgesi olan ülkemizde inşa edilecek yapıların tasarımcılarına öneriler sunulmuştur.

Çırak 2011’de betonarme yapılarda görülen hasarları ve nedenlerini bir çalışma kapsamında incelemiştir. Taşıyıcı elemanlarda meydana gelen eğilme, kesme ve burulma hasarları ayrı ayrı ele alınmış, bunun yanında taşıyıcı olmayan elemanlarda oluşan çatlaklara da değinilmiştir. Çalışmanın sonucunda yapı denetim uygulamalarının yaygınlaştırılması gerektiğine ve bir yapı inşa edilirken yürürlükteki yönetmelik kurallarına ciddi riayet edilmesi gerektiğine değinilmiştir.

Çöğür (2014) çalışmada; düşük kalitede beton kullanımı, çeşitli mimari düzensizlikler, taşıyıcı elemanlarda yetersiz donatılandırma, etriye aralıklarının fazla tutulması, zayıf ve yumuşak kat oluşumları, zayıf kolonlar ve güçlü kirişlerden kaynaklanan hasarları incelemiştir. Çalışma sonucunda bahsedilen bu nedenlerden dolayı binaların ağır hasar almaması amacıyla basit bir yapım sistemi seçilmesi gerektiği, yatay

yüklerin taşıyıcı bileşenler arasında aktarılması gerektiği ve plastik deformasyonların stabilite kaybı gerçekleşmeksizin tüm bileşenler tarafından alınması gerektiği vurgulanmıştır.

Er ve ark, 2013'te yaptıkları çalışmalarında depremde en çok hasar alan bölgelerden biri olan kolon-kiriş birleşim bölgesinin aldığı hasarlar üzerinde durmuşlardır. Bu amaçla gerçek uygulamalarda meydana gelen kusurları (ettriye sıklaştırılmasının yapılmaması, düşük dayanımlı beton kullanımı ve kabul beton dökülmesi) içeren deney elemanları oluşturulmuştur. Referans numuneden elde edilen yük-sehim grafiği ile kusurlu numunelerden elde edilen yük-sehim grafikleri karşılaştırılmıştır. Deneyler sonucunda referans numunede eğilme taşıma gücüne giriş ulaşırken, diğer elemanlarda kolon-kiriş birleşim bölgesi ulaşmıştır. Böylece yapıda ciddi hasarların oluşması kaçınılmaz hale gelmiştir.

Işık ve Özdemir 2017 yılında yaptıkları çalışmalarında, güçlü kiriş-zayıf kolon ilişkisini incelemek amacıyla tasarlanan bir betonarme binada ilk olarak zemin kattaki kirişleri güçlü kiriş olarak tasarlamış, daha sonra aynı betonarme binada kirişleri normal duruma getirerek statik hesaplamalarını gerçekleştirmişlerdir. Çalışma sonuçları göstermiştir ki, yönetmeliklere uygun şekilde tasarlanan betonarme binalar deprem sırasında sünek davranış gösterip minimum hasar seviyesinde kalırken, diğer binada ciddi hasarlar oluşmaktadır.

Özyürek ve Beyen (2019), betonarme yapılarda meydana gelen zayıf ve yumuşak kat düzensizliklerinin deprem sırasında yapıya verdikleri zarar üzerinde çalışmışlardır. Düzensizlik bulunmayan, zayıf kat düzensizliği bulunan ve yumuşak kat düzensizliği bulunan üç ayrı yapının modellendiği çalışmada, kolonlara etki eden kesme kuvvetleri ve görelî kat ötelenmeleri kıyaslanmıştır. Zayıf kat düzensizliği bulunan yapıda kesme kuvvetlerinin, yumuşak kat düzensizliği bulunan yapıda ise deplasmanların hiçbir düzensizlik bulunmayan yapıya kıyasla ciddi şekilde arttığı gözlemlenmiştir.

Terzi ve Elçi (2009), Türkiye Bina Deprem Yönetmeliği-2018 (TBDY-2018)'de A2 türü düzensizlik olarak geçen döşeme süreksizliği üzerinde çalışmışlardır. Çalışma kapsamında; döşeme süreksizliklerinin sağ alt köşede olduğu, simetrik olduğu ve rastgele yerleştirilmiş olduğu üç farklı model tasarlanarak analizler yapılmıştır. Çalışma sonucunda döşeme boşluklarının büyüklükleri kadar yapının neresinde konumlandırıldığının da önemli olduğu görülmüştür.

Yılmaz 2019 yılında yaptığı çalışmasında, TBDY-2018'de bulunan tüm düzensizlik durumlarının ve kısa kolon, çekiçleme, zayıf kolon-güçlü kiriş, yetersiz

donatılandırma gibi sorunların nedenlerini, sonuçlarını ve alınabilecek önlemleri incelemiştir. Sonuç olarak, yönetmeliğe uygun şekilde yapı tasarlamının olası depremlerde daha az hasar alan yapıların inşa edilmesine olanak sağlayacağı belirtilmiştir.


Yön ve Sayın 2008 yılında, kısa kolonların betonarme yapılara etkisini inceleyen bir çalışma yapmışlardır. Söz konusu çalışma kapsamında, zemin ve birinci katlarında kısa kolon oluşumu gözlenen ve gözlenmeyen iki ayrı yapı modellenmiştir. Yapılan analizler sonucu deprem hasar düzeylerinin kısa kolonlarla beraber çok daha arttığı gözlemlenmiştir.

Yüksel (2008) çalışmasında, deprem sonrası betonarme binaların hızlı bir şekilde hasar tespit çalışması yapan bilirkişiler tarafından incelenmesi konusunun altını ciddi şekilde çizerek, söz konusu çalışmaların zorluklarından bahsetmiştir. Bu güçlüklerin üstesinden gelmek amacıyla sık karşılaşılan yapısal hasarlar ayrıntılı şekilde irdelenmiş, acil şekilde yapılması gereken hasar tespit çalışmalarındaki değerlendirme kriterleri açıklanmıştır.

3. YAPAY ZEKÂ VE DERİN ÖĞRENME

İnsanları yaratılmış diğer tüm canlılardan ayrılan en önemli özelliği beyni ve karar verebilme mekanizmasıdır. İnsanoğlu bu mekanizmayı cansız varlıklar üzerinde uygulamak istemiş, bu istek ve merak doğrultusunda ‘yapay zekâ’ terimi ortaya çıkmıştır. Bu kavram, sayısal bir mantık sağlama, konuşma, hareket, ses algılama, insana özgü davranışlar gösterme gibi birçok yeteneği beraberinde taşımaktadır (Sucu ve Ataman, 2020).

Herkes tarafından merak duyulan, gelişmeleri sıkı bir şekilde takip edilen YZ kavramının tek bir tanımı bulunmamaktadır. “İnsansı zekânın makineler tarafından taklidi, akıllı eşyalar yapma bilimi” vb. gibi tanımlara sahip olan YZ kavramının Oxford Sözlüğü’ndeki tanımı “*Görsel algılama, konuşma tanıma, karar verme ve diller arasında çeviri gibi normalde insan zekâsı gerektiren görevleri yerine getirebilen bilgisayar sistemlerinin teorisi ve gelişimi*” olarak verilmiştir (Demirkol, 2019). YZ’nin kullanım alanları Şekil 3.1’de gösterilmiştir.



Şekil 3.1. YZ’nin kullanım alanları

Disiplinler arası bir araştırma alanı olan YZ, insan hayatını önemli ölçüde kolaylaştırmaktadır. Örneğin, bir inşaat mühendisinin köprü tasarlayacağı zaman bu köprünün kasırgalara karşı dayanıklı olup olmayacağı hakkında bilgi sahibi olmak için köprüyü inşa edip yüzyılda bir gerçekleşecek olan kasırgayı beklemesi saçma olacaktır. Bu durumda inşaat mühendisleri bilgisayar simülasyonlarına ve dolayısıyla YZ'ye başvurmaktadır (Whitby, 2003).

Günümüzde insanları ciddi derece şaşırtan YZ sistemleri 2010'lu yıllardan itibaren hayatımıza girmiştir. Bunlara fotoğraf tanıma, sohbet robotları, yabancı dil çevirileri örnek verilebilir. YZ gelişiminin 2010 yılından itibaren önemli derecede ilerlemesi tesadüf değildir. Söz konusu tarihten itibaren bilgisayarların donanımsal özellikleri ve teknolojinin gelişmesi YZ'nin altyapısını oluşturmuştur. Kısa bir kronoloji oluşturulmak istenirse 1950'lerde YZ ile ilgili ilk çalışmalar yapılmış, 1980'lerde MÖ uygulamaları geliştirilmeye başlanmış ve 2010'larda ise DÖ ve derin sinir ağları uygulamaları ortaya çıkmıştır (Demirkol, 2019).

Makinelerin kendi kendilerine öğrenmesi olarak tanımlanabilen MÖ son yıllarda YZ'nin en dikkat çekici alanlarından biri olmuştur. Herkesin bildiği geleneksel kural tabanlı sistemlerde yani programlamada veriler ve kurallar insanlar tarafından sisteme verilip sistemden cevaplar alınmaktadır. Ancak MÖ'de sisteme veriler ve cevaplar verilip çıktı olarak kurallar alınmaktadır. Klasik programlamada her veri değişiminde kurallar da bizim tarafımızdan değiştirilmelidir. MÖ'de bu işleme gerek yoktur çünkü, sistem veriler arasında mevcut bulunan örüntüyü matematiksel formüllere dökerek yeni veriler hakkında tahmin veya öngöründe bulunabilmektedir (Demirkol, 2019). MÖ yönteminin geliştirilmesiyle ortaya çıkan DÖ herhangi bir veri setinden öğrenerek, sonuçları tahmin edebilen bir algoritmadır. MÖ'de verilerin nitelikleri manuel olarak sisteme verilirken, DÖ algoritmalarında verilerin nitelikleri sistem tarafından otomatik çıkarılmaktadır. Bu anlamda DÖ, çok daha gelişmiş ve hızlı bir yöntemdir. Diğer yöntemlere kıyasla son yıllarda popülerliğini hızla artıran DÖ, özellikle görüntü sınıflandırma alanında sıklıkla tercih edilmektedir. Bu yöntemlerin yanı sıra insan beyninde bulunan sinirlerden ve bunların kendi aralarında oluşturdukları ağ yapısından ilham alınarak geliştirilen YSA'nın amacı ise kendi kendilerine öğrenerek yeni bilgiler türetmektir. Birden çok katmandan meydana gelen YSA'larda bir katmandan elde edilen çıktı bir sonraki katmanın girdi değerini oluşturmaktadır. Sınıflandırma, kontrol, tahmin, teşhis, yorumlama, veri filtreleme ve ilişkilendirme gibi alanlarda kullanılan YSA'da bulunan hücreler, karmaşık işlemleri gerçekleştirebilme kabiliyetine sahiptir (URL 1).

Bahsedilen MÖ, YSA ve DÖ gibi YZ tekniklerinin temelinde üç unsur bulunmaktadır. Bunlar; veri, matematik ve hesaplama. Üç unsurdan birini oluşturan veri, YZ'nin yakıtı olarak da görülmektedir. Verilerin YZ uygulamalarında anlamlı olması için çok fazla miktarda olması gerekmektedir. Bunun yanında YZ uygulamaları tarafından yapılan matematiksel işlemleri ve hesaplamaları doğru ve hızlı bir şekilde uygulamak için güçlü donanımlara sahip bilgisayarlar gerekmektedir. Teknolojinin gelişmesi ile ortaya çıkan GPU ve CPU'lar araştırmacılara bu imkânı sunmaktadır (Demirkol, 2019).


DÖ, görev ve özellikleri; doğrudan ses, görüntü veya metinden oluşan verilerden öğrenebilen; insan beyninin karmaşık yapısından ilham alınarak oluşturulmuş, YZ'nin en dikkat çekici alanlarından biri olan MÖ'nün alt dalıdır (Tan, 2019). Şekil 3.2'de DÖ'nün YZ ile ilişkisi gösterilmiştir.



Şekil 3.2. DÖ ile YZ arasındaki ilişki


Mimarisi tıpkı bir YSA'ya benzese de DÖ'yü YSA'dan ayıran en önemli özelliği karmaşık problemlerde daha iyi sonuçlar almayı mümkün kılan gizli katman sayısının fazlalığıdır (Cuşkun, 2019). Öte yandan DÖ'nün en etkileyici kısımlarından biri verilerden özellik çıkarımı işlemini kendi kendine gerçekleştirebilmesidir. Bir MÖ algoritmasında veriler ön işlem sürecinden geçirilirken DÖ'de bu adımlar atlanarak görüntü piksellerine dayalı sınıflandırmalar gerçekleştirilir (Baydilli, 2020). Öğrenmenin derin katmanlarda gerçekleşmesi algoritmaya “derin öğrenme” ismini kazandırmıştır, katman sayısı arttıkça modelin derinliği de artar. Her katman, kendinden önceki katmanda üretilen çıktı değerini girdi olarak kullanır (Şeker ve ark, 2017). Ayrıca veri boyutu ve miktarı arttıkça da algoritmanın daha başarılı sonuçlar verdiği gözlemlenmiştir. Şekil

3.3'te veri sayısı arttıkça DÖ ve MÖ modellerinin gösterdiği performans bir grafik şeklinde gösterilmiştir.



Şekil 3.3. DÖ ve MÖ yöntemlerinin veri sayısı-performans grafiği (Alom ve ark, 2018)

İlk ortaya çıkışı 1950'li yıllardan öncesine dayanan DÖ'deki ilk kayda değer çalışma 1965 yılında yapılan Ivakhnenko ve Lapa'ya ait olan çalışmadır. Daha sonra 1979'da kendi kendini eğitebilen bir ağ yapısı Fukushima tarafından ortaya çıkarılmıştır. 2000'lerden sonra ise Geoffrey Hinton çok katmanlı ileri beslemeli sinir ağları ile daha başarılı sonuçlar almayı başarmıştır (Şeker ve ark, 2017). DÖ, ilk ortaya çıktığı yıllara nazaran, 2000'li yıllardan sonra oldukça gelişen teknoloji ile beraber günümüzde çok daha popüler hale gelmiştir. Şekil 3.4'te "deep learning (derin öğrenme)" kelimesinin son on yılda dünya genelinde Google arama motorunda aranma sıklığı bir grafik şeklinde verilmiştir.



Şekil 3.4. "deep learning" kelimesinin son on yılda Google'da aratılma sıklığı (URL 2)

DÖ'de sinir ağları; girdi, aktivasyon fonksiyonu, ağırlık ve çıktı olarak dört temel bileşenden oluşmaktadır (Güngen, 2020). Kısaca özetleyecek olursak öğrenme işlemi basamakları şu şekilde sıralanabilir; önce rastgele belirlenen ağırlıklar yardımıyla modelin tahmin ettiği çıkış değeri bulunur, tahmin edilen çıkış ile gerçek çıkış arasındaki

fark alınarak hata değeri hesaplanır. Hesaplanan hatanın geri yayılım algoritması ile her katmana göre türevi alınır ve rastgele belirlenen ağırlık değeri güncellenir. Bu işlem adımları hata değeri istenen düzeye gelene kadar tekrarlanır. Hata değeri istenilen düzeye geldiğinde optimum ağırlık değeri bulunur ve öğrenme işlemi tamamlanmış olur (Cuşkun, 2019). DÖ, çeşitli alanlarda sıklıkla kullanılan bir YZ modeli haline gelmiştir. DÖ yönteminin kullanım alanları;

- Görüntü sınıflandırma,
- El yazısı tanıma,
- Çeviri,
- Yüz algılama,
- Metin analizi,
- Ses tanıma,
- Nesne tanıma,
- Doğal dil işleme,
- Akıllı asistanlar ve
- Robotiktir (Gülğün, 2020).

DÖ yöntemleri, Şekil 3.5'te verildiği gibi Evrişimli Sinir Ağları (ESA), Tekrarlayan Sinir Ağları (TSA), Uzun Kısa Süreli Hafıza Ağları (UKSHA), Sınırlı Boltzmann Makineleri (SBM), Derin İnanç Ağları (DİA) ve Derin Oto Kodlayıcılar (DOK) olmak üzere altı alt başlıkta incelenebilmektedir (Şeker ve ark, 2017).




Şekil 3.5. DÖ mimarileri

3.1. Derin Sinir Ağları

İnsan beyninin öğrenme ve bilgiyi işleme mekanizmasından esinlenerek geliştirilen YSA modelinin çok katmanlı hali olarak tanımlanabilen derin sinir ağları, genel olarak giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. ‘Derin’ sıfatının nedeni gizli katman sayısının çok fazla olmasıdır. Daha ilkel olarak nitelendirilebilen tek katmanlı algılayıcılar doğrusal sınıflandırma işlemlerinde başarı gösterirken, derin sinir ağları doğrusal olmayan sınıflandırma görevlerinde oldukça başarılıdır. Derin sinir ağlarına girdi olarak tanımlanacak veriler genelde eğitim ve test seti olmak üzere ikiye ayrılmaktadır. Eğitim setinin amacı modelde oluşacak ağırlık değerlerini optimum şekilde saptamak, test setinin amacı ise bu ağırlık değerlerinin doğruluğunu sınamaktır (Ser ve Bati, 2019). Birbirinden farklı görevleri gerçekleştirmek için kullanılan çeşitli derin sinir ağları bulunmaktadır.

3.1.1. Tekrarlayan Sinir Ağları (TSA)

DÖ’nün modellerinden biri olan TSA, ilk olarak Jeff Elman tarafından 1990’lı yıllarda ‘Basit Tekrarlayan Sinir Ağları’ başlığı altında ortaya koyulmuştur. Bu yöntemde nöronlar arasındaki bağlantılar bir döngü oluşturmakta, söz konusu döngü sayesinde bir ağ yapısı oluşmaktadır (Şeker ve ark, 2017). Şekil 3.6’da TSA modeli gösterilmiştir. Tam bağlantılı bir sinir ağı olan TSA, YSA’nın hafıza eklenmiş hali olarak tanımlanabilmektedir (Demirkol, 2019).




Şekil 3.6. TSA mimarisi (Akinosho ve ark, 2020)

Zaman serisi veya sıralı şekilde ifade edilen verileri işlemek için ortaya çıkarılan TSA'ların ana fikri ardışık bilgileri kullanmaktır. Görüntülerden oluşan veri seti ile işlem yapılırken modele verilen bütün girdilerin birbirinden bağımsız olduğu farz edilmektedir. TSA mimarisi doğal dil işleme, video işleme ve ses işleme gibi birbirinden farklı alanlarda kullanılmaktadır. Zamana bağlı verileri işleyerek gelecek hakkında tahmin yapmada kullanılan en başarılı algoritmadır (Şeker ve ark, 2017; Gülgün, 2020).

3.1.2. Uzun Kısa Süreli Hafıza Ağları (UKSHA)

TSA'da bulunan problemleri gidermek amacıyla UKSHA modeli ortaya çıkmıştır. TSA'nın problemini bir örnek ile açıklamak gerekirse şu şekilde açıklanabilir; Örneğin "Bitki toprakta büyür." Cümlesindeki toprak sözcüğünü tahmin etmek basittir. Fakat "Türkiye'de doğup büyüdüm. Güzel bir şekilde Türkçe konuşabiliyorum" cümlelerindeki "Türkçe" sözcüğünün yerine herhangi bir dil adı geleceğini model tahminleyebilir ancak hangi dil olduğunu tahminleyebilmek için ilk cümleye başvurması ve bunu hafızaya kaydetmesi gerekir. Burada uzun vadeli bağımlılıklar devreye girmektedir. Tüm bu sorunları aşabilmek amacıyla UKSHA, 1997 yılında Hochreiter ve Schmidhuber tarafından ortaya çıkarılmıştır (Şeker ve ark, 2017). Şekil 3.7'de UKSHA mimarisi gösterilmiştir.




Şekil 3.7. UKSHA mimarisi (Ismail ve ark, 2018; Kılınç, 2021)

Söz konusu mimari, gereksiz ve fazla bilgileri unutup nispeten daha işe yarar bilgileri bellekte tutarak daha iyi bir performans vermeyi amaçlamaktadır. Gradyenlerin yok olması problemiyle karşılaşmamak için hiperbolik tanjant aktivasyon fonksiyonu

kullanılmıştır. UKSHA mimarisi, metin veya konuşma işleme gibi alanlarda çok iyi performans sergilemektedir (Gülgün, 2020).

3.1.3. Sınırlı Boltzmann Makineleri (SBM)


Aslında 1986 yılında Harmonium ismiyle ortaya çıkan SBM, 2006 yılında Geoffrey Hinton ve meslektaşları tarafından yeniden gündeme getirilmiştir. Regresyon, nitelik öğrenimi ve sınıflandırma gibi işlemleri başarılı bir şekilde gerçekleştirebilen SBM, modele girdi olarak verilen veri seti üstünde olasılıksal dağılımları öğrenebilmektedir. Söz konusu mimari girdi ve gizli katman olmak üzere iki katmandan oluşmaktadır (Şeker ve ark, 2017; Doğan, 2019). SBM, ayrıca Boltzmann Makineleri'nin görünür ve gizli bağlantılara sahip olmamalarını kısıtlayarak öğrenme sürecini basitleştirmektedir (Li ve ark, 2014). Şekil 3.8'de SBM mimarisi gösterilmiştir.



Şekil 3.8. SBM mimarisi (Li ve ark, 2014)

3.1.4. Derin İnanç Ağları (DİA)


SBM'nin yığını olarak kabul edilen ve Goffrey Hinton tarafından 2009 yılında ortaya çıkarılan DİA, en sonda bulunan softmax katmanı sayesinde sınıflandırma veya kümeleme işlemlerinde kullanılmaktadır (Şeker ve ark, 2017). Bir başka deyişle, SBM'de gösterilmiş olan gizli katmanlar DİA'da görünür katman olarak kabul edilip katmanlar art arda sıralanmaktadır. Şekil 3.9'da DİA mimarisi verilmiştir.



Şekil 3.9. DİA mimarisi (Akinosho ve ark, 2020)

3.1.5. Derin Oto-Kodlayıcılar (DOK)


Denetimsiz öğrenme için kullanılmakta olan DOK, “Diablo ağı” olarak da bilinmektedir. Son yıllarda oldukça fazla kullanılmaya başlanan DOK, girdi verilerinden iyi nitelikleri öğrenmeye çalışır. Bir katmanda oluşan çıktı değeri diğer katmanda girdi değeri olarak kullanılmaktadır. Şekil 3.10’da DOK mimarisi gösterilmiştir. Model girdi verilerini şifreleyerek özellik 1’i oluşturmakta ve oluşturulan bu özellik 1 verisi sıradaki katmanda girdi olarak kullanılmaktadır. Bir sonraki katmanda girdi verileri şifrelenerek özellik 2 verisi oluşturulmakta ve diğer katmanda girdi verisi olarak kullanılmaktadır. Son olarak softmax katmanında sınıflandırma işlemi gerçekleştirilmektedir (Şeker ve ark, 2017).



Şekil 3.10. DOK mimarisi (Akinosho ve ark, 2020)

3.1.6. Evrişimli Sinir Ağları (ESA)


ESA, lineer olmayan fonksiyonların bulunduğu birden fazla evrişim katmanından meydana gelen, ağırlıklı olarak görüntü tanıma ve sınıflandırma amacı ile kullanılan DÖ modellerinden biridir. 1950’li yıllarda Wiesel ve Hubel’in hayvan korteksini modeliği çalışma, modelin ilk ortaya çıkışı olarak kabul edilmektedir. ESA, iki ayrı kısımdan oluşmaktadır; bunlardan birincisi evrişim işlemi ve filtreler yardımıyla nispeten daha basit özelliklerin görüntülerden çıkarıldığı tam bağlantılı katmana kadar olan kısım, ikincisi ise daha soyut ve karmaşık özelliklerin çıkarılıp elde edilen tüm özellikler modele aktararak sınıflandırma işleminin gerçekleştirildiği tam bağlantılı katman ve sonraki kısımdır. Öğrenme işlemi birinci kısımda optimum filtrenin, ikinci kısımda ise optimum ağırlığın bulunmasıyla gerçekleşmektedir (Cuşkun, 2019). Genel anlamda sırasıyla giriş katmanı, evrişimli katman, havuzlama katmanı, tam bağlantılı katman ve sınıflandırma katmanından meydana gelmektedir (Malkoçoğlu, 2020). Şekil 3.11’de ESA katmanları gösterilmiştir.



Şekil 3.11. ESA katmanları

Öncelikle sınıflandırılması amaçlanan görüntü renk kanallarına (kırmızı, yeşil, mavi) ayrılır. Başlangıçta rastgele belirlenen filtre ile kanallarına ayrılan görüntü evrişim işlemine sokulur ve belirli özellikler çıkarılır. Çok sayıda özellik çıkarmak için çok sayıda filtre kullanılmalıdır. Çıkarılan özelliklere doğrusal olmayan nitelikler kazandırmak amacıyla aktivasyon fonksiyonları devreye girer. Daha sonra veri sayısını düşürmek amacıyla ortaklama işlemi gerçekleştirilir. Tüm bu işlemler istenilen sayıda tekrar edilir. Çıkarılan özellikler istenilen niteliğe ve sayıya ulaşıncaya sınıflandırma kısmına aktarım gerçekleştirilir. Bu katmanda tahmin çıkışı ile gerçek çıkış değeri arasındaki fark hata fonksiyonunu vermektedir. Bu fonksiyonun her bir katmana göre türevi alınıp filtreler ve ağırlıklar güncellenir. Hata değeri istenilen seviyeye ulaştığında bu işlem durdurulur ve

sınıflandırma gerçekleşmiş olur (Cuşkun, 2019). Tüm bu anlatılan işlemler Şekil 3.12’de gösterilmiştir.



Şekil 3.12. ESA eğitim süreci


Çalışma kapsamında bahsedilen DÖ mimarilerinin özellikleri karşılaştırmalı şekilde Çizelge 3.1’de gösterilmiştir.

Çizelge 3.1. DÖ mimarileri için genel uygulama alanları (Akinosho ve ark, 2020)

Derin Öğrenme Mimarileri	Anahtar Fonksiyon	Genel Uygulama Alanları									
		Görüntü Sınıflandırma	Resim Altyazısı	Nesne Algılama	Nesne İzleme	Anlamsal Segmentasyon	Ekinlik Tanıma	Veri Artırma	Sıra Tanıma	Desen Tanıma	Özellik Çıkarma
Evrişimli Sinir Ağları	Görüntü modelleme	✓	✓	✓	✓	✓	✓	x	x	✓	✓
Tekrarlayan Sinir Ağları	Dizi modelleme	x	✓	✓	✓	✓	✓	x	✓	x	x
Derin Oto Kodlayıcılar	Boyutsal küçülme	x	✓	✓	✓	✓	✓	✓	x	x	✓
Kısıtlı Boltzmann Makineleri	Yüksek seviyede özellik çıkarma	✓	x	✓	✓	✓	✓	x	x	x	✓
Derin İnanç Ağları	Lineer olmayan boyutsal küçülme	✓	x	✓	✓	✓	✓	✓	✓	✓	✓

ESA'nın katmanları giriş katmanı, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman ve sınıflandırma katmanı olarak sıralanmaktadır.


Giriş katmanı, ESA'nın ilk katmanıdır. Burada veri olduğu gibi yani ham olarak katmana verilir ancak dikkat edilmesi gereken en önemli konu görüntü boyutunun seçimidir (Güngen, 2020). Görüntü boyutu yüksek olarak seçilirse eğitim ve test süresi artar ve bellek ihtiyacı sorunu ortaya çıkar. Fakat sonuçta modelin başarısı artabilir. Görüntü boyutu düşük seçilirse eğitim ve test süresiyle orantılı olarak bellek ihtiyacı da azalacaktır ancak bu durum modelin başarısını düşürebilir. İdeal veri girişini bulmak bu nedenlerden dolayı oldukça önemlidir (Tan, 2019). Ham olarak ağıza verilen görüntüyü sistemin anlayabilmesi için görüntü piksellerine sayısal değerler atanır. Örneğin yüksekliği ve genişliği 224 olan görüntü eğer gri ise matrisi $224 \times 224 \times 1$; renkli ise matrisi $224 \times 224 \times 3$ 'tür. Renkli görüntülerdeki 3 değeri, renk kanallarının kırmızı, mavi, yeşil olmak üzere üçe ayrılmasından kaynaklanmaktadır (Darıcı, 2020). Şekil 3.13'te görüntünün matris değerleri gösterilmiştir.



Şekil 3.13. Görüntü ağırlık bağlantısı (Baydan, 2021)


Evrişim katmanı, modeldeki temel hesaplamaların gerçekleştiği ve ESA için en önemli adımlardan biridir. Bu katmanda daha önce bahsedilen filtreler bulunmaktadır. Filtreler 3×3 , 5×5 , 7×7 gibi çeşitli boyutlarda olabilir. Filtre görüntü üzerinde gezdirilmeden önce görüntü matrislere dönüştürülür ve bir çıkış değeri hesaplanır. Belirlenen boyuttaki filtre, belirlenen adım sayısı ile görüntü üzerinde kaydırılarak özellik çıkarma işlemi uygulanır. Örneğin adım sayısı 1 seçildiğinde filtre görüntü üzerinde 1 piksel kaydırılacaktır. Her filtreleme işlemi sonucunda elde edilen niteliklerle özellik haritası oluşturulur. Burada bahsedilen özellikler renkler, şekiller, kenarlar, eğrilikler

olabilir. Adım (stride) değeri, elde edilen özellik haritasının boyutunu etkilemektedir. (Çınar, 2020). Evrişim işlemi sonucunda elde edilen görüntü boyutu baştaki görüntü boyutundan küçüktür ancak boyutları yönetmek araştırmacının elinde olan bir durumdur. Şekil 3.14'te görüntü, görüntünün matrisi, kullanılan filtre ve elde edilen özellik haritası matrisi gösterilmiştir.



Şekil 3.14. 7x7'lik görüntü matrisi üzerinde 3x3'lük bir filtrenin 1 adım değeri ile kaydırılmasından elde edilen özellik haritası matrisi

Yukarıdaki örnekte ilk olarak görüntünün 7x7'lik matrisi çıkarılmış, daha sonra bu görüntü matrisi üzerinde 3x3'lük filtre 1 adım değeri ile gezdirilmiş sonuç olarak ise özellik haritası çıkarılmıştır. Şekil 3.15'te söz konusu adım kaydırma işlemi gösterilmiştir.




Şekil 3.15. 7x7'lik görüntü matrisi üzerinde 3x3'lük filtrenin 1 adım değeri ile kaydırılma işlemi

Denklem 1'de evrişim işleminin matematiksel denklemi verilmiştir.

$$f_1^k(p, q) = \sum_c \sum_{x, y} i_c(x, y) \cdot e_1^k(u, v) \quad (1)$$

Denklemden p ve q değerleri özellik matrisinde bulunan satır ve sütun değerlerini, $f_1^k(p, q)$ her işlemde elde edilen özellikleri, F_1^k özellik haritasını, $i_c(x, y)$ piksel değerlerini ve $e_1^k(u, v)$ filtre değerlerini temsil etmektedir (Açııcı, 2021).

Evrişim katmanında görüntünün boyutunun küçülmesi bilgi kaybına neden olacaktır. Burada bilgi kaybını önlemek, yani küçülen görüntüyü büyütme ve diğerlerine nispeten daha az hesaba katılan kenar piksellerin daha fazla hesaba katılmasını sağlamak amacıyla görüntünün etrafı sıfırlarla ya da kenar piksel değerleriyle doldurulur. Bu şekilde görüntünün boyutu sabit kalmaktadır (Cuşkun, 2019; Çınar, 2020). Bu işleme piksel doldurma (padding) adı verilir ve “zero padding” ve “same padding” olmak üzere iki farklı şekilde uygulanmaktadır. Bunlardan birincisinde matrisin dışına yeni bir çerçeve eklenir ve buradaki piksel değerleri 0 olarak atanır, ikincisinde ise eklenen çerçevedeki piksel değerleri görüntünün piksel değerleri ile doldurulur. Şekil 3.16'da “zero padding” yöntemi ile piksel doldurma işlemi yapılmış görüntü matrisinden elde edilmiş özellik haritası matrisi gösterilmiştir.



Şekil 3.16. Görüntü matrisine piksel doldurma işlemi uygulandıktan sonra elde edilen özellik haritası matrisi

Evrişim ve piksel doldurma işlemlerinden sonra elde edilen özellik haritası matrisinin büyüklüğü aşağıda verilen denklemler yardımıyla hesaplanabilir.

$$G = \frac{W - F + 2P}{S} + 1 \quad (2)$$




$$Y = \frac{H - F + 2P}{S} + 1 \quad (3)$$

Denklem 2'deki "W" ile gösterilen değer görüntü matrisinin genişliğini, "F" ile gösterilen değer filtre matrisinin genişliğini, "P" ile gösterilen değer doldurma işlemi uygulanmışsa doldurma elemanını, "S" ile gösterilen değer ise filtrenin görüntü üzerinde kaç birim kaydırılarak gezdirildiğini yani adım sayısını ve son olarak "G" ile gösterilen değer ise çıkışta elde edilecek olan matrisin genişliğini temsil etmektedir. Denklem 3'te verile "H" değeri görüntü matrisinin yüksekliğini, "F" değeri filtre matrisinin yüksekliğini, "P" değeri doldurma elemanını, "S" değeri adım sayısını ve son olarak "Y" değeri ise çıkışta elde edilecek olan matrisin yüksekliğini temsil etmektedir.


Aktivasyon katmanında, görüntüleri ağırlık anlayabileceği hale getirmek amacıyla doğrusal bir yapı bu katmanda doğrusal olmayan yapıya çevrilir. Temel görevi nöron çıkış değerini sınırlandırıp belli aralıkta işlem yapılmasını sağlamaktır. Sık kullanılan aktivasyon fonsiyonlarına ReLU, softmax, adım, doğrusal, sızdıran ReLU, sigmoid, hiperbolik tanjant örnek verilebilir. DÖ'de en çok kullanılan fonksiyon ise ReLU fonksiyonudur (Malkoçoğlu, 2020). Aktivasyon fonksiyonlarının kısa açıklamaları, denklemleri ve grafikleri Çizelge 3.2'de verilmiştir.

Çizelge 3.2. Sık kullanılan aktivasyon fonksiyonları

Fonksiyon ismi	Açıklaması	Denklemi	Grafiği
Adım	İkili sınıflandırma için kullanılan, girdinin belirli bir eşik değerinin (a) altında veya üstünde olmasına göre 0 veya 1 değerini aldığı aktivasyon fonksiyonudur. Türevi sıfır değerini alacağından dolayı gizli katmanlarda tercih edilmeyip genelde çıkış katmanında kullanılmaktadır (Çınar, 2020).	$f(x) = \begin{cases} x \leq a & \text{ise } x = 0 \\ x > a & \text{ise } x = 1 \end{cases}$	
Doğrusal	Genelde regresyon analizlerinde kullanılan, girdiyi doğrudan çıktı katmanına gönderen aktivasyon fonksiyonudur. Türev değeri sabit olacağından karmaşık problemlerde yetersiz kalacaktır (Çınar, 2020).	$-\infty < a < \infty$ $f(x) = a \cdot x$	
Sigmoid	Genelde ikili sınıflandırmalarda tercih edilen, çıkış değerini 0 ile 1 arasında sınırlayan ve en sık kullanılan aktivasyon fonksiyonlarından biridir. Dezavantajı gradienlerin yok olması problemi bulunmasıdır. Bu durumda öğrenme minimum seviyede gerçekleşir veya bütünüyle biter ve bu sebeple algoritma istenilen performansı gösteremez (Qanbar, 2019).	$f(x) = \frac{1}{1 + e^{-x}}$	
Hiperbolik tanjant	Sigmoid aktivasyon fonksiyonunun çalışma prensibine benzer olan hiperbolik tanjant aktivasyon fonksiyonu sigmoid fonksiyonundan farklı olarak -1 ile 1 arasında çıkış değerleri üretir. Gradiyenlerin yok olma problemi bu fonksiyonda da bulunmaktadır ancak, sıfır odaklı olması nedeniyle sigmoid fonksiyonuna nazaran daha sık tercih edilmektedir (Cuşkun, 2019).	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

ReLU	Özellikle görüntü ile ilgili yapılacak sınıflandırma işlemlerinde sıklıkla tercih edilmektedir. Herhangi bir üstel fonksiyon bulunmadığından dolayı sigmoid ve hiperbolik tanjant fonksiyonlarına göre daha hızlı çalışır. Girdi olarak gelen negatif değerleri sıfıra eşitlerken pozitif değerler olduğu gibi kalır. Fakat girdilerin çoğu negatif değerlerden oluşuyor ise çok fazla bilgi kaybına neden olur ve bu durum ağıın öğrenmesini önüne geçer (Malkoçoğlu, 2020; Cuşkun, 2019).	$f(x) = \begin{cases} x & \text{ise } x \geq 0 \\ 0 & \text{ise } x < 0 \end{cases}$	
Sızdıran ReLU	ReLU fonksiyonundan farklı olarak bilgi kaybını önlemek amacıyla negatif değerleri 0,01 ile çarpar, pozitif değer ise aynı kalır (Malkoçoğlu, 2020).	$f(x) = \begin{cases} 0,01 \cdot x & \text{ise } x < 0 \\ x & \text{ise } x \geq 0 \end{cases}$	
Softmax	0 ila 1 arasında çıktı değeri üreten, verileri normalleştirmek amacıyla birçok YZ modelinde kullanılan, tüm olasılıkların toplamının 1'e eşit olduğu aktivasyon fonksiyonudur (Qanbar, 2019; Ashames, 2020). Kimi zaman çoklu sigmoid olarak adlandırılan softmax aktivasyon fonksiyonu çoklu sınıflandırma işlemlerinde tercih edilmektedir (URL 3).	$f(x) = \frac{e^x}{\sum_i^j e^x}$	

Havuzlama katmanında amaç, aktivasyon fonksiyonundan geçen özellik haritasını ortalama ya da maksimum havuzlama gibi yöntemlerle yeniden boyutlandırıp, tekrar evrişim katmanına aktarılmasını sağlamaktır. En yaygın kullanılan havuzlama işlemi maksimum havuzlamadır (Malkoçoğlu, 2020). Bu yöntemle üzerinde çalışılmakta olan veri boyutu azaltılarak sistemin ezberlemesinin önüne geçilmektedir. Şekil 3.17'de maksimum ve ortalama havuzlama işlemlerine örnek gösterilmiştir.




Şekil 3.17. Özellik haritası matrisine maksimum ve ortalama havuzlama işlemlerinin uygulanması

Denklem 4'te havuzlama katmanında yapılan işlem matematiksel olarak gösterilmiştir.

$$Z_1^k = g_p(F_1^k) \quad (4)$$


Denklem 4'teki F_1^k özellik matrisini, g_p havuzlama işleminin ortalama veya maksimum havuzlama vb. çeşidini ve son olarak Z_1^k havuzlama sonucunda elde edilen matrisi temsil etmektedir (Açıcı, 2021).

Havuzlamanın ardından elde edilen matrisin tam bağlantılı katmana aktarılması gerekir fakat, tam bağlantılı katman sadece tek boyutlu bir dizi şeklindeki matrisleri kabul etmektedir. Bu nedenle havuzlama katmanında elde edilen matrisin tek boyutlu dizi haline getirildiği düzleştirme (flattening) katmanı devreye girer (Coşkun, 2020). Şekil 3.18'de 4x4'lük bir matrisin düzleştirilmiş hali gösterilmiştir.



Şekil 3.18. Düzleştirme işleminin uygulanması


Temelde ileri beslemeli YSA olan tam bağlantılı (fully connected) katman kendisinden önce ve sonra gelen aktivasyon ünitelerinin hepsini birbirine bağlar. ESA mimarisinde veriyi sınıflandırmak için uygulanan son aşamadır (Coşkun, 2020). Şekil 3.19’da tam bağlantılı katman temsili olarak gösterilmiştir.



Şekil 3.19. Tam bağlantı katmanının temsili gösterimi

ESA mimarisindeki ağ yapılarının büyüklüğü dolayısıyla nöronlar öğrenmeden ziyade ezberleme yapabilmektedir. Ezberleme durumunun önüne geçmek ve algoritmanın başarısını artırmak amacıyla rastgele ya da belli aralıklarla seçilen bazı nöronlar seyreltme (dropout) katmanında etkisizleştirilir. Diğer bir deyişle bazı düğüm

noktaları kaldırılır. Bu seyreltme işlemi gereksiz verilerin öğrenilmesini engellemektedir (Malkoçoğlu, 2020). Şekil 3.20’de seyreltme katmanı temsili olarak gösterilmiştir.



Şekil 3.20. Seyreltme işlemi uygulanmasının temsili gösterimi

Sınıflandırma katmanı, ESA’nın son katmanıdır. Bu katmanda algoritmaya verilen girdiler daha önceden belirlenmiş olan sınıflara ayrılır. Örneğin bir görüntü sınıflandırma işleminde model, verilen görüntünün ne olduğunu tahmin eder ve buna göre çıktı oluşturup görüntünün hangi sınıfa ait olduğunu tespit eder. Genelde softmax katmanı sınıflandırıcı olarak kullanılmaktadır (Malkoçoğlu, 2020; Aydilek, 2020).

3.2. Derin Sinir Ağlarında Kullanılan Parametreler

MÖ ya da DÖ’de araştırmacının vermesi gereken bazı kararlar, yapması gereken tercihler vardır ki bu karar ve tercihler oluşturulan algoritmanın performansını doğrudan etkilemektedir. Parametre olarak adlandırılan söz konusu tercihler model parametreleri ve iyileştirici parametreler olmak üzere ikiye ayrılmaktadır. Aktivasyon fonksiyonları, katman sayıları, seyreltme değeri model parametrelere örnek verilebilirken; epoch, batch boyutu, öğrenme oranı gibi parametreler ise iyileştirici parametrelere örnek gösterilebilmektedir. Tüm bu parametrelerin değeri algoritmaya, probleme ve veriye göre değişebilir, önceden belirli olmamaktadır. Araştırma yapan kişi daha önceki tecrübelerine dayanarak veya deneme-yanılma yöntemi ile optimum parametre değerlerini bulmaya çalışmaktadır. Buradaki amaç oluşturulan modelin performansını maksimum seviyeye taşımaktır (Çınar, 2020).

DÖ yönteminde en sık kullanılan parametrelere; epoch sayısı, veri boyutu, öğrenme hızı, batch boyutu, optimizasyon algoritmasının seçimi, iletim sönümlleme değeri, aktivasyon fonksiyonu, filtre boyutu, havuzlama, gizli katman sayısı örnek verilebilir (Çınar, 2020).

3.2.1. Döngü (Epoch)

DÖ’de eğitime bütün veriler aynı anda katılmaz. Veriler belirli sayılarda gruplara ayrılır. İlk grup eğitime girdiğinde modelin elde ettiği başarıya göre geri yayılım gerçekleşir ve ağırlıklar güncellenir. Bu şekilde tüm veriler eğitime gruplar halinde katılırlar. Bu adımların her birine “epoch” adı verilmektedir. İlk epochlarda ağırlık değerleri rastgele belirlendiği için başarı düşük olacak, ilerleyen epochlarda başarı oranı giderek yükselecektir. Epoch sayısının büyüklüğü modelden modele veya problemde problemde değişiklik gösterir (URL 4). Söz konusu epoch sayısını küçük seçmek en küçük hata değerine ulaşmayı engelleyebilirken, büyük seçmek gereksiz tekrarlara ve eğitim sürecinin uzamasına neden olabilmektedir (Demirkol, 2019).

3.2.2. Erken durdurma (Early stopping)


Problemde belirlenen epoch sayısı arttıkça aşırı uyum söz konusu olmaktadır. Bu durumu ortadan kaldırmak amacıyla epoch ile beraber erken durdurma değeri de belirlenmeli ve bu sayede tekrar, öğrenmenin durduğu noktada durdurulmalıdır (Çınar, 2020).

3.2.3. Veri boyutu

Bilindiği gibi DÖ’de veri boyutu arttıkça modelin başarısı da artmaktadır. Veri setinin yetersiz olduğu durumlarda veri artırma yöntemine gidilebilir, burada söz konusu olan görüntüyü farklı derecelerde çevirmek, simetriğini almak, renk tonları ile oynamak, görüntüyü bulanıklaştırmak veya küçültüp büyültmektir (Tan, 2019). Boyutunun yanında verilerin çeşitliliği de önemlidir. Tüm bunlara ilaveten veri setinin büyüklüğü depolama ve zaman açısından dezavantajlar sağlayacağından optimum veri boyutu büyüklüğünü başarılı şekilde ayarlamak gerekir (Güngen, 2020).

3.2.4. Öğrenme hızı

MÖ algoritmalarında en önemli parametrelerden biri olan öğrenme hızı çok küçük seçilirse modelin ilerlemesi çok yavaş olacak dolayısıyla zaman kaybı yaşanacaktır. Ancak bu sayı çok büyük seçilirse modelin öğrenme işlemi gerçekleştiremeyecek ve başarı yakalanamayacaktır. Bu nedenlerden dolayı optimum öğrenme hızını belirlemek oldukça önemlidir. DÖ uygulamalarından en popüler olanı öğrenme hızını 0,1 ile 0,000001 arasında seçmektir. İlk oluşturulan modelde öğrenme hızı yüksek belirtilir, diğer modellerde bu sayı azaltılır (Çınar, 2020). Şekil 3.21’de öğrenme hızının küçük veya büyük seçilmesi halinde oluşabilecek maliyet-ağırlık grafiklerine yer verilmiştir. İlk grafik öğrenme hızının düşük seçildiği durumu göstermektedir. Optimum değerleri bulmak için çok fazla işlem yapılmış dolayısıyla zaman açısından dezavantaj oluşturmuş ve nitelikli bilgisayar donanımı gerekliliği ortaya çıkmıştır. İkinci grafikte ise yüksek öğrenme hızının seçildiği durum gösterilmiştir. İşlem basamaklarının az olması optimum ağırlık değerlerinin yakalanamamasına yol açmış ve modelin başarısının maksimuma ulaşmasını önlemiştir.



Şekil 3.21. Öğrenme hızının düşük seçildiği durumlarda oluşan kayıp-ağırlık grafiği (a), yüksek seçildiği durumlarda oluşan kayıp-ağırlık grafiği (b) (Demirkol, 2019)

3.2.5. Yığın boyutu (Batch size)

DÖ’de eldeki verilerin hepsini aynı anda eğitime sokmak bellek ve zaman açısından oldukça maliyetli bir iştir. Bu sorun, veri setini belirli sayılarda küçük gruplara ayırarak çözülmüştür. Verilerin gruplar halinde işlenmesi işlemine “batch” adı

verilmektedir. Araştırmacının batch parametresi olarak sisteme atadığı değer modelde aynı anda kaç verinin işleneceğini belirlemektedir (URL 4). Bu değer, probleme ve veri boyutuna göre değişkenlik gösterse de sıklıkla kullanılan batch değerleri 8, 16, 32, 64, 128, 256'dır (Çınar, 2020). Örneğin 500 veri ile işlem yapılacağı durumlarda eğitim verisi 50'lik batchlere bölünerek 10 epochta eğitimin bir aşaması gerçekleşmektedir (Demirkol, 2019).

3.2.6. Ağırlık (Weight)

Yapılan çalışmalarda, başta belirlenen ağırlık değerlerinin modelin hızında ve öğrenmesinde oldukça etkili olduğu gözlemlenmiştir. Araştırmacının modeline göre seçeceği ağırlık değerleri farklılık gösterir ancak sıfır veya sıfıra yakın değerler aynı sonucu çıkaracağı için öğrenme gerçekleşemez bu nedenle söz konusu değerlerden uzak durulması gerekir (URL 4).

3.2.7. Seyreltme değeri

Bu değer tam bağlantılı katmandan sonra gelen, derin sinir ağları modellerinin ezberleme durumunu ortadan kaldırmak amacıyla eklenen seyreltme (dropout) katmanında hangi nöronların devre dışı bırakılacağını belirlemek için kullanılır. Belirli bir eşik değerinin altındaki nöronlar devre dışı bırakıldığında yani zayıf bilgiler unutulduğunda modelin başarısının arttığı gözlemlenmiştir. Aynı zamanda bu değer araştırmacının problemine göre rastgele seçilebilir, genellikle 0,5 değeri kullanılmaktadır (URL 4).

3.2.8. Bias değeri

Lineer fonksiyonlar Denklem 5'te verildiği gibi gösterilmektedir.

$$y = W.x + b \quad (5)$$

Bu fonksiyonda W, ağırlık parametresi değerlerini; x, girdi değerlerini; b, bias değerini; y ise çıktı değerini temsil etmektedir. Örneğin bir kelebek resmini tanımlıyorsak x değeri kelebek görüntüsünün matrisini, y değeri ise görüntünün kelebeğe ne kadar

benzediğini ifade eder. Aslında DÖ modellerinde belirlenen temel hedef maksimum başarımın alınmasını sağlayacak W ve b değerlerinin bulunmasıdır. Çünkü x değeri modelin girdisini oluşturur ve araştırmacı tarafından değiştirilemez. Bununla birlikte W değeri çarpım durumunda olduğundan dolayı sürekli x değeri ile birlikte hareket eder. Ayrıca x değeri 0 olduğunda W parametresi anlamını yitirecek ve öğrenme gerçekleştirilemeyecektir. Bu nedenlerle başarılı bir sonuç elde edebilmek için x 'ten bağımsız hareket eden b değerine ihtiyaç vardır (URL 5). Türkçe “önyargı, varsayım, yanlılık, sapma” gibi anlamlara gelen bias değeri eğrinin diğer noktaları arasında optimum konuma yerleşebilmesini sağlamaktır. Yani bias değeri, $W.x$ lineer doğrusunu öteleyerek daha iyi sonuçlar alınmasını sağlar. Bir model oluşturulurken temel gaye bias değerini düşük tutmaktır. Çünkü varsayım anlamına gelen biasın yüksek olması model çıktılarının varsayımlara dayandığını göstermektedir (Demirkol, 2019).

3.2.9. Optimizasyon fonksiyonları

DÖ problemlerinde optimum değerleri bulmak amacıyla kullanılan fonksiyonlara optimizasyon fonksiyonu adı verilmektedir (URL 4). Modelin tahmin ettiği değer ile doğru değer arasındaki farkı minimuma indirgeyerek algoritmanın başarısını en yüksek düzeye taşımayı amaçlayan ve DÖ uygulamalarında sıkça kullanılan optimizasyon fonksiyonlarına AdaGrad, Adam, Stokastik gradyan iniş metodu (SGD), AdaDelta, RMSProp gibi fonksiyonlar örnek verilebilir (Malkoçoğlu, 2020). Çizelge 3.3'te sık kullanılan optimizasyon fonksiyonlarının açıklamasına ve denklemlerine yer verilmiştir.


Çizelge 3.3. Sık kullanılan optimizasyon fonksiyonları

Optimizasyon fonksiyonu	Açıklaması	Denklemi
SGD	Yüksek boyutlu optimizasyon işlemlerinde hesaplama yükünü azaltan SGD optimizasyon fonksiyonu, her eğitim örneği için ağırlık güncellemesi yapmaktadır. Buradaki amaç yerel minimuma daha erken ulaşarak daha hızlı sonuçlar elde edebilmektir. SGD optimizasyon yöntemi bu avantajının yanında maliyet fonksiyonlarında yarattığı dalgalanma nedeniyle dezavantaj sağlamaktadır (Malkoçoğlu, 2020; Güngen, 2020)	$\theta = \theta - n. \nabla_{\theta} J(\theta; x(i); y(i))$

AdaGrad	SGD optimizasyon yöntemindeki sabit öğrenme katsayısı sorununu ortadan kaldırmak amacıyla geliştirilmiştir. Önceki gradyanların kareleri toplamı alınarak her adımda öğrenme katsayısı güncellenir. Öğrenme hızını parametrelerin değişme oranına göre ayarlamaktadır. Sık değişenler için öğrenme hızı daha küçük adımlarla, nispeten daha az değişenler için öğrenme hızı daha büyük adımlarla güncellenmektedir. Ancak her durumda öğrenme oranı azalmaktadır (Malkoçoğlu, 2020).	$\theta_{t+1} = \theta_t - \frac{n}{\sqrt{\epsilon + \sum g_t^2}} g_t$
RMSprop	RMSprop optimizasyon yöntemi AdaGrad yönteminin özel bir uzantısı olup büyük oranda benzerlik göstermektedir. Öğrenme oranını her bir parametre için rastgele bir şekilde farklı olarak seçmektedir (Güngen, 2020).	$\theta_{t+1} = \theta_t - \frac{n}{\sqrt{E[g^2]_t + \epsilon}} g_t$
Adam	Adam optimizasyon yöntemi nispeten daha az bellek ihtiyacı gerektiren ve verimli bir yöntemdir. Uygulaması basit olduğundan son yıllarda oldukça popüler olan bu yöntem, AdaGrad ve RMSprop yöntemlerinin birleştirilmesiyle ortaya çıkmıştır (Cengiz, 2020).	$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$ $v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$ $\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$ $\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$ $\theta_{t+1} = \theta_t - \frac{n}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t$
AdaDelta	AdaGrad optimizasyon yönteminin dezavantajlarını ortadan kaldırmak amacıyla geliştirilen AdaDelta optimizasyon yönteminde diğer yöntemlerin aksine öğrenme katsayısı seçme zorunluluğu yoktur (Malkoçoğlu, 2020).	$\Delta\theta_t = - \frac{[\sqrt{E[\Delta\theta^2]_t + \epsilon}]_{t-1}}{[\sqrt{E[g^2]_t + \epsilon}]_t} g_t$ $\theta_{t+1} = \theta_t + \Delta\theta_t$

θ , model parametrelerini; n , öğrenme katsayısını; $\nabla_{\theta} J(\theta; x(i); y(i))$, hedef fonksiyonun eğimini; $\sum g_t^2$, tahminlerin karelerinin toplamını; ϵ ise 10^{-8} sabit sayısını, v_t , geçmiş eğimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamalarını; m_t , momentum değişikliklerini; β_1 , 0,9 sabit değerini; β_2 , 0,999 sabit değerini temsil etmektedir.

Seyyarer ve ark. tarafından 2020 yılında yapılan bir çalışmada SGD, Adam, AdaGrad, RMSProp ve AdaDelta optimizasyon fonksiyonlarının karşılaştırılması yapılmıştır. Elde edilen başarı oranları Şekil 3.22’de verilen grafikte gösterilmiştir.



Şekil 3.22. Farklı optimizasyon algoritmalarından elde edilen başarı oranları (Seyyarer ve ark, 2020)

3.2.10. Kayıp (Loss) Fonksiyonu

DÖ modelleri kullanılarak yapılan tahminlerde elde edilen hata oranını en aza indirmek amacıyla çıkış katmanında kullanılan fonksiyonlara kayıp/maliyet/hata fonksiyonu adı verilmektedir. Algoritma sonucunda elde edilen tahmin değeri gerçek değere ne kadar yakınsa yani kayıp değeri ne kadar küçükse model o kadar başarılıdır (Tan, 2019).

Temelde iki çeşit kayıp fonksiyonu bulunmaktadır. Çizelge 3.4'te ortalama kare hata ve çapraz entropi olarak adlandırılan iki kayıp fonksiyonunun açıklaması ve denklemleri verilmiştir.

Çizelge 3.4. Sık kullanılan kayıp fonksiyonları

Kayıp fonksiyonu	Açıklaması	Formülü
Ortalama kare hata	Tahminleyici algoritmanın performansını ölçmek için kullanılır. Hata değerlerini normale göre abartarak göstermesi ve eksi hata değerlerini pozitif çevirerek hata toplamına katmasından dolayı sıklıkla tercih edilmektedir. Aykırı değerlere karşı çok duyarlı olması bu kayıp fonksiyonun dezavantajını oluşturmaktadır. Sonuçta elde edilen değer sıfıra ne kadar yakınsa fonksiyonun o kadar başarılı performans sergilediği söylenebilir (URL 6; Demirkol, 2019).	$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2$

Çapraz entropi


Bu fonksiyonda gerçek değerler ile tahmin sonucu elde edilen değerler arasında bir karşılaştırma yapılır ve aralarındaki fark kadar ceza puanı uygulanır. Model gerçek değere ne kadar yakın bir tahmin değeri üretirse o kadar az ceza puanı hesaplanacaktır. Daha çok ikili sınıflandırmalarda kullanılmaktadır (Malkoçoğlu, 2020).

$$H(T, q) = - \sum_{i=1}^N \frac{1}{N} \log_2 q(x_i)$$

N , test kümesinin büyüklüğünü; $q(x)$, olayın olasılığını; x_i gerçek değerleri, y_i tahmin değerlerini; n , örnek sayısını temsil etmektedir.

3.2.11. Az Öğrenme (Underfit) ve Ezberleme (Overfit) Durumları

Bir MÖ algoritmasının amacı, daha önce hiç karşılaşmadığı veriler hakkında tahminde bulunmak için eğitim verilerinden yola çıkarak problem ile ilgili tüm verilere genelleme yapmaktır. Başka bir deyişle, algoritma sadece eğitimi aldığı veri kümesi ile değil aynı zamanda daha önce eğitimi almadığı veri kümesi üzerinde de başarılı bir performans göstermelidir. Şekil 3.23'te başarılı öğrenme durumu grafik şeklinde gösterilmiştir.




Şekil 3.23. Başarılı şekilde gerçekleşen öğrenme durumu (Çınar, 2020)

MÖ algoritmalarında istenilen bu başarının yakalanamama nedenlerinden birisi yeterli uyumun sağlanamadığı az öğrenme diğeri ise aşırı uyum nedeniyle ortaya çıkan ezberleme durumlarıdır.


Bilindiği gibi ESA modelinde ilk olarak eğitim verileri yardımıyla model eğitilir, daha sonra test verileri yardımıyla da eğitilmiş olan model test edilir. Bu aşamalar gerçekleştikten sonra eğitim ve test arasındaki hata oranı farkının yüksek çıkması az

öğrenme (underfitting) durumunun gerçekleştiğine işaret eder. Bu durumun nedeni, eğitim verilerinin model üzerinde yeterli derecede çalıştırılmamasıdır (Malkoçoğlu, 2020). Veri sayısının veya modelin karmaşıklığının artırılması bu sorunu ortadan kaldırabilir. Şekil 3.24'te az öğrenme durumu grafiksel bir şekilde gösterilmiştir.




Şekil 3.24. Az öğrenme (Underfit) durumu (Çınar, 2020)

Az öğrenme durumunun tam tersi ezberleme (overfitting) durumu ise eğitim verilerinin model üzerinde aşırı derecede çalışmasıyla ortaya çıkan bir sorundur. Eğer algoritma ezberleme durumuna geçmişse eğitim verilerinde çok yüksek başarı oranı elde edilirken test verilerinde bu başarı oranı önemli ölçüde azalacaktır. Ezberleme yapmış bir modelde bir diğer handikap modeli ifade eden matematik formüllerinin çok karmaşık olmasıdır. Karmaşık matematiksel formüller daha fazla işlem gücüne ihtiyaç duymaktadır (Demirkol, 2019). Ezberlemenin önüne geçmek için modelin girdileri azaltılabilir, seyreltme tekniği uygulanabilir, veri sayısı artırılabilir veya erken durdurma yöntemi uygulanabilir (URL 7). Şekil 3.25'te ezberleme durumu bir grafik şeklinde gösterilmiştir.



Şekil 3.25. Ezberleme (Overfit) durumu (Çınar,2020)

Şekil 3.26'da ise az ve aşırı öğrenme durumları tek bir grafik üzerinde gösterilmiştir. Grafikten de görüleceği gibi optimum model karmaşıklığı sağlandığında tahmin hatası minimum değerde kalacaktır. Modelde kullanılan test verisi miktarı optimum düzeyin altında kaldığında az öğrenme durumu gerçekleşmekte ve buna bağlı olarak hata oranı da yüksek çıkmaktadır. Test verisi miktarı optimum değeri aştığında ise aşırı öğrenme durumu gerçekleşmekte ve yine buna bağlı olarak hata oranı artmaktadır.




Şekil 3.26. Az ve aşırı öğrenme durumları (Malkoçoğlu, 2020)

3.2.12. Veri Artırma (Data Augmentation)

DÖ yöntemlerinde veri sayısı ile algoritma başarısı doğru orantılıdır. Ancak elde edilebilen veri miktarı kısıtlı olabilir. Bu gibi durumlarda araştırmacılar veri artırma

metodu ile halihazırda bulunan görüntüler üzerinde çeşitli oynamalar yaparak istenilen optimum veri sayısına ulaşabilmektedir. Bunun yanında az öğrenme ya da ezberleme durumlarının önüne geçmek amacıyla veri miktarının artırılması yöntemi sıklıkla kullanılmaktadır.

Görüntüler her zaman eğitim verisindeki aynı açı ile modele girdi olarak verilemeyeceğinden dolayı araştırmacılar sıklıkla görüntü üzerinde döndürme işlemini veri artırma sırasında uygulamaktadır (Çınar,2020). Bunun dışında görüntüler yeniden boyutlandırılarak, bulanıklaştırılarak, keskinleştirilerek, renkleriyle oynanarak, aynalama yapılarak, parlaklaştırılarak veya soldurularak veri artırımı yapılabilir. Örnek bir veri artırma Şekil 3.27’de gösterilmiştir.



Şekil 3.27. Örnek bir veri artırma (URL 8)

3.2.13. Isı Haritaları (Heatmap)

ESA’ya girdi olarak verilen görüntülerin sınıflandırılması yapılırken, algoritmanın görselin tam olarak neresine odaklandığı önemli bir detaydır. Modelden elde edilen başarı oranı çok yüksek çıksa bile eğer farklı yerlere odaklanmışsa model başarısız sayılmaktadır. Bu kararı verebilmek için ısı haritaları denilen yöntem başvurulmaktadır. Örneğin kedi ve köpek arasında bir sınıflandırma yapan algoritmada, ısı haritaları köpek


sınıfı için girdinin hangi bölümlerinin köpeğe benzediğini göstermektedir. Söz konusu haritalar, araştırmacılara ağırların neden o görselde bir kedi veya köpek olduğunu düşündüğünü ve görselin neresinde kedi veya köpek olduğunu göstermektedir (Chollet, 2019). Şekil 3.28’de ısı haritalarına örnek gösterilmiştir. Kırmızı ve sarı bölgeler, modelin yoğunlukla odaklandığı bölgeler olarak yorumlanabilirken mavi bölgeler ise aktivasyonun en az olduğu bölgelerdir.



Şekil 3.28. Kedi ve köpek resimleri arasında sınıflandırma yapan algorithmandan elde edilen ısı haritaları (URL 9)

3.3. Transfer Öğrenme

Günlük hayatımızda bizler, daha önce öğrendiğimiz herhangi bir bilgiyi yeni karşımıza çıkmış bir durum veya olayda kullanabiliriz. Problemlerin benzer olması arasındaki ilişkiyi kurabilmek için yeterlidir. Transfer öğrenme, bu olayın makineler tarafından yapılmasını amaçlayan ve son yıllarda YZ alanında sıkça kullanılan bir yöntemdir. Kısaca transfer öğrenme, makinenin önceden geliştirilen modelin bilgilerini saklayıp benzer bir problemle karşılaştığı zaman bu bilgileri kullanmasıdır. Geleneksel öğrenmede bir model eğitimi çok zaman alan ve oldukça uğraştırıcı bir eylemdir. Çok fazla veriye ihtiyaç vardır ve bu nedenle çok güçlü donanımlar gerektirir. Burada devreye transfer öğrenme yöntemi girmektedir. Transfer öğrenmenin amacı eğitim süresini minimuma indirmek ve performansı yükseltmektir. Şekil 3.29’da transfer öğrenme metodu kullanılarak ve kullanılmadan oluşturulan modellerin eğitim-performans grafiği verilmiştir.



Şekil 3.29. Transfer öğrenme metodu uygulanmış ve uygulanmamış modellerin eğitim- performans grafiği (Torrey ve Shavlik, 2009)

Bu alanda özellikle yaklaşık 1000 sınıflı görüntü verisinden oluşan ImageNet, veri seti sıklıkla kullanılmaktadır. Probleme bağlı olarak araştırmacılar tarafından VGGNet, Inception, AlexNet, GoogleNet, ResNet gibi çeşitli transfer öğrenme mimarileri kullanılmaktadır (Çınar, 2020; Tan, 2019).


Önceden eğitilmiş bir modelin yeni sınıflandırma probleminde kullanılması için;

- Yeni sınıf sayısı ve önceden hesaplanmış ağırlıklar ile modelin tamamını eğitmek,
- Katmanlardan bazılarını eğitip kalanları devre dışı bırakmak,
- Evrişim katmanlarını devre dışı bırakmak

gibi ince ayarlardan herhangi birinin uygulanması gerekir (Ashames, 2020).

3.3.1. AlexNet


AlexNet, her birinde yaklaşık 1000 görüntü olan 1000 farklı sınıfta toplam 1,2 milyon eğitim, 50 bin doğrulama ve 150 bin test görüntüsünden oluşan; Krizhevsky tarafından 2012 yılında tasarlanmış bir modeldir. Beş evrişim, üç tam bağlantılı katman olmak üzere toplam sekiz katmandan oluşmaktadır. Birinci katmanında 11x11x3 boyutunda 96 filtre, ikinci katmanında 5x5x48 boyutunda 256 filtre, üçüncü katmanında 3x3x256 boyutunda 384 filtre, dördüncü katmanında 3x3x192 boyutunda 384 filtre ve son olarak beşinci katmanında 3x3x192 boyutunda 256 filtre bulunmaktadır. Evrişim katmanlarının her birinden sonra ReLU aktivasyon fonksiyonu bulunmaktadır ve maksimum havuzlama yöntemi kullanılmıştır. Bu sayede hata oranı %26'dan %15,3'e düşürülmüş ve 2012 yılında düzenlenen Büyük Ölçekli Nesne Tanıma Yarışması'nı kazanmıştır (Malkoçoğlu, 2020). Şekil 3.30'da AlexNet mimarisi verilmiştir.



Şekil 3.30. AlexNet mimarisi (Krizhevsky, 2012)

3.3.2. ZFNet

AlexNet'ten farklı olarak ilk katmanında 11x11'lik filtrelemeye karşın 7x7'lik filtre kullanılmıştır. Buradaki mantık, daha küçük boyutlu filtre kullanılmasının orijinal piksel değerlerinin korunmasına yardımcı olacağı düşüncesidir. (İnik ve Ülker, 2017). Matthew Zeiler ve Rob Fergus tarafından 12 gün boyunca eğitilen ve 2013 yılında düzenlenen yarışmada hata oranını %11,2'ye indirgeyerek birinci olan transfer öğrenme modelidir (Çınar, 2020). Şekil 3.31'de ZFNet mimarisi gösterilmiştir.




Şekil 3.31. ZFNet mimarisi (Çınar, 2020)

3.3.3. VGGNet

AlexNet üzerinde yapılan iyileştirmeler sonucu ortaya çıkan 11x11 veya 7x7 gibi büyük boyutlu filtreler yerine 3x3'lük daha küçük boyutlu filtreler kullanan 2014 yılında düzenlenen yarışmada sunulmak üzere Simonyan ve Zisserman tarafından tasarlanan bir modeldir (Malkoçoğlu, 2020). Yarışmada hata oranını %7'ye kadar düşürme başarısını elde etmişler fakat 2. olmuşlardır (Güngen, 2020). Veri seti olarak bin sınıfa ait yaklaşık

14 milyon görüntü kullanılmıştır (Qanbar, 2019). İki farklı VGG modeli bulunmaktadır, bunlar; 16 katmandan meydana gelen VGG 16 ve 19 katmandan meydana gelen VGG 19'dur. Şekil 3.32'de VGG 19 mimarisi, çizelge 3.5'te katmanları verilmiştir.



Çizelge 3.5. VGG 19 mimarisinin katman listesi


Katman tipleri		Çıkış şekli	Parametreler
Giriş katmanı		(224, 224, 3)	0
1.Blok	1. Evrişim katmanı	(224, 224, 64)	1792
	2. Evrişim katmanı	(224, 224, 64)	36928
	Maksimum havuzlama katmanı	(112, 112, 64)	0
2.Blok	1. Evrişim katmanı	(112, 112, 128)	73856
	2. Evrişim katmanı	(112, 112, 128)	147584
	Maksimum havuzlama katmanı	(56, 56, 128)	0
3.Blok	1. Evrişim katmanı	(56, 56, 256)	295168
	2. Evrişim katmanı	(56, 56, 256)	590080
	3. Evrişim katmanı	(56, 56, 256)	590080
	4. Evrişim katmanı	(56, 56, 256)	590080

	Maksimum havuzlama katmanı	(28, 28, 256)	0
4.Blok	1. Evrişim katmanı	(28, 28, 512)	1180160
	2. Evrişim katmanı	(28, 28, 512)	2359808
	3. Evrişim katmanı	(28, 28, 512)	2359808
	4. Evrişim katmanı	(28, 28, 512)	2359808
	Maksimum havuzlama katmanı	(14, 14, 512)	0
	1. Evrişim katmanı	(14, 14, 512)	2359808
5.Blok	2. Evrişim katmanı	(14, 14, 512)	2359808
	3. Evrişim katmanı	(14, 14, 512)	2359808
	4. Evrişim katmanı	(14, 14, 512)	2359808
	Maksimum havuzlama katmanı	(7, 7, 512)	0
	Düzleştirme katmanı	(25088)	0
	1.Tam bağlantılı katman	(4096)	102764544
	2.Tam bağlantılı katman	(4096)	16781312
	Sınıflandırma katmanı	(1000)	4097000

3.3.4. GoogLeNet

GoogLeNet, 22 katmandan oluşan 2014 yılında düzenlenen yarışma için tasarlanmış, Szegedy ve arkadaşları tarafından ortaya koyuluş bir transfer öğrenme modelidir. Modelde 1x1, 3x3, 5x5 boyutlarındaki filtreler ve 3x3 boyutundaki havuzlama katmanı birleştirilip tek bir sonuç elde edilmiştir. Birbirine paralel şekilde bağlanmış yapılardan oluşan GoogLeNet'in AlexNet'e göre işlem yükü 12 kat daha azdır. 2014 yılında düzenlenen çalışmada hata oranı %6,67'ye düşürülmüş ve birinci olmuştur (Malkoçoğlu, 2020; Tan, 2019).


Ayrıca GoogLeNet, Prof. Dr. Yan LeCun'un tasarladığı LeNet'ine saygı göstermek amacıyla isminin içinde "LeNet" kelimesini de içerir. Bir diğer ismi ise Inception-v1'dir (Ashames, 2020). Şekil 3.33'te GoogleNet mimarisi gösterilmiştir.



Şekil 3.33. GoogleNet mimarisi (URL 11)


3.3.5. ResNet

Şimdiye kadar oluşturulan bütün mimarilerden daha derin şekilde tasarlanan ResNet mimarisi 152 katmandan meydana gelmiştir. Giriş kısmı diğer modellere benzerken önceki katmandan sonraki katmana atlama bağlantısı oluşturularak tasarlanmış, bu sayede karmaşıklık azaltılmıştır. He ve arkadaşları tarafından 2015 yılında tasarlanan modelde, diğer transfer öğrenme modellerinden farklı olarak artık değerler sonraki katmanları besleyerek devam ettirilmiştir. Şekil 3.34'te de görüleceği üzere normal durumda x girdi değerinden oluşan çıktı değeri bir sonraki katmanın girdi değeri olarak kabul edilip katmanlar sırasıyla ilerlerken ResNet mimarisinde herhangi bir katmanda ağırlık değerinin sıfır olması halinde yaşanacak bilgi kaybının önüne geçebilmek amacıyla katmanlar arasında kısayol bağlantıları oluşturulmuştur (URL 12).




Şekil 3.34. Normal durum ile ResNet mimarisinde oluşan durumun karşılaştırılması (URL 12)

ResNet modeli, 2015'te düzenlenen yarışmada hata oranı değerini %3,57'ye kadar düşürerek birincilik elde etmeyi başarmıştır (Malkoçoğlu, 2020; Güngen, 2020). Şekil 3.35'te ResNet mimarisi gösterilmiştir.



Şekil 3.35. ResNet mimarisi (URL 12)

Şekil 3.36’da verilen grafikte ise daha önce bahsedilen transfer öğrenme modellerinde elde edilen hata oranları verilmiştir.




Şekil 3.36. Farklı transfer öğrenme modellerinin hata oranları grafiği

İnsanların öğrendiği herhangi bir durum üzerinden karşılaştığı benzer olaylar karşısında yapabildiği tahminin hata oranı %5’tir. 2012 yılından bu yana geliştirilen ve düzenlenen yarışmalarda birincilik alan transfer öğrenme modellerinden elde edilen hata oranları bu değerlerle karşılaştırıldığında özellikle VGGNet, GoogLeNet, ResNet gibi modellerin oldukça başarılı olduğu görülmektedir.

2015 yılından bu yana yapılmış çalışmalar baz alınarak farklı transfer öğrenme modellerinin zaman içinde kullanım sıklıkları Şekil 3.37’de grafik şeklinde gösterilmiştir.

Çalışmada, daha önce inşaat mühendisliği alanında yapılmış DÖ çalışmalarında kullanılan ve başarısı kanıtlanmış VGG19 modeli tercih edilmiştir.



Şekil 3.37. Çeşitli transfer öğrenme modellerinin zaman içinde kullanımı (URL 13)

3.4. Python ve Uygulama Kütüphaneleri

Yaygın inancın aksine ismini piton yılanından değil, tasarımcısı olan Guido van Rossum'un izlemekten keyif aldığı Monty Python isimindeki komedi grubunun oynadığı bir gösteriden alan Python, 1990'lı yılların başında geliştirilmeye başlanmıştır. Nesne yönelimli, modüler ve etkileşimli, yorumsal, yüksek seviyeli bir programlama dilidir. Web uygulamaları, masaüstü uygulamaları, veri görselleştirme, veri analizi ve finansal hesaplamalar gibi pek çok alanda Python kullanılmaktadır (Cuşkun, 2019).

İnsan mantığı ile makine mantığı arasında köprü vazifesi gören Python, oldukça fazla sayıda işi diğer programlama dillerine göre nispeten daha az kodla yapabildiğinden dolayı son yıllarda sıklıkla tercih edilmektedir. Ayrıca Python programlama dilinin açık kaynak kodlu olması programcılıkla ilgilenen topluluğun hızlı bir şekilde gelişmesini sağlamaktadır. Yazılan kodlarda bir açık fark edildiğinde programla ilgilenen kişi sayısının çok fazla olması bu açığın kısa sürede kapanmasına yardımcı olacaktır. Ara yüzünde bulunan kütüphaneler sayesinde MÖ ve veri bilimi alanlarında önemli bir yere sahiptir (URL 14). Python kütüphanelerinin kısa açıklamaları Çizelge 3.6'da verilmiştir. Bilgisayarlı görü çalışmalarında görüntü üzerinde yapılan sınıflandırma işlemlerinde sıkça kullanılan Keras ve TensorFlow kütüphaneleri bu çalışmada tercih edilen Python kütüphaneleridir.

Çizelge 3.6. Python kütüphaneleri.

Amblem	Kütüphane	Açıklama
	Keras	2015 yılında François Chollet tarafından tasarlanan, arka planda TensorFlow ve Theano kütüphanelerini kullanan, DÖ'de sıklıkla tercih edilen bir kütüphanedir. Literatürde fazlaca kullanılan ESA modellerini içeren Keras kütüphanesi hızlı ve kolay olduğundan dolayı kullanıcı dostudur. GPU ve CPU ile sorunsuz çalışma avantajı sunmaktadır (Çınar, 2020).
	TensorFlow	2015 yılında Google tarafından MÖ ve YSA için geliştirilmiştir. Python programlama dilinin yanında Java, C++, C#, R ve Javascript gibi dilleri de desteklemektedir (Malkoçoğlu, 2020). TensorFlow kullanarak uygulama oluşturmak kolay olduğundan en sık tercih edilen kütüphane haline gelmiştir. Bunun yanında dünya çapında kullanılan bir kütüphane olduğu için araştırmacı karşılaştığı sorunu arama motorunda arattığında çözümünü kolayca bulabilmektedir ki bu durum da tercih edilme nedenlerinden birisini oluşturmaktadır (Çınar, 2020). Kütüphanede Google tarafından eğitilmiş DÖ modelleri de bulunmaktadır. Görüntü işleme, ses tanıma, video algılama, Google Translate gibi alanlarda kullanılmaktadır (Tan, 2019).
	Numpy	Bilimsel hesaplamalar için kullanılan temel bir kütüphane olan Numpy kütüphanesi; matris oluşturma, çarpma, toplama gibi işlemleri hızlı bir şekilde gerçekleştirir.
	Scikit-learn	Regresyon, sınıflandırma, boyutlandırma, kümeleme gibi işlemler için kullanılan, MÖ için geliştirilmiş bir kütüphanedir (Malkoçoğlu, 2020).
	PyTorch	Facebook, Torch ve PyTorch şirketleri tarafından ortak geliştirilen bir DÖ kütüphanesidir. Kolay kullanımı nedeniyle son yıllarda popülerlik kazanan kütüphanelerden biridir (Qanbar, 2018).
	Matplotlib	Python programlama dilinde yazılmış; 2 boyutlu görseller üzerinde işlem yapma, grafik arayüzü oluşturma, çizelge, histogram, verileri yeniden ölçeklendirme gibi görselleştirme işlemlerinde kullanılan 2 boyutlu çizim kütüphanesidir (Malkoçoğlu, 2020).
	OpenCV	OpenCv, bünyesinde bulunan algoritmalar sayesinde yüz tanıma, plaka okuma, nesne sınıflandırma, nesneleri ayırt etme, optik karakter tanımlamanın içinde bulunduğu 2500'den fazla ayrı işlem yapılabilen bir kütüphanedir (URL 15).

**Caffe**

Görüntü sınıflandırma gibi DÖ mimarilerini destekleyen Berkeley Vision and Learning Center tarafından geliştirilmiş bir Python kütüphanesidir (Cuşkun, 2019).

theano**Theano**

2007 yılında Montreal Üniversitesi'nde geliştirilen özellikle matris hesaplamalarında yararlanılan bir Python kütüphanesidir (Cuşkun, 2019). Fazla miktarda veri içeren problemlerde yüksek hızlarda sonuç verdiğinden dolayı DÖ algoritmalarında kullanılmaktadır.




4. DEPREM VE BETONARME YAPI HASARLARI

TDK sözlüğünde, “*Yer kabuğunun derin katmanlarının kırılıp yer değiştirmesi veya yanardağların püskürme durumuna geçmesi yüzünden oluşan sarsıntı, yer sarsıntısı, hareket, zelzele*” olarak tanımlanan deprem kavramı can ve mal kaybına neden olan doğal afetler sıralamasında birinci sırada yer almaktadır. Çizelge 4.1’de çeşitli doğal afetlerde ciddi derecede hasar görmüş yapı sayıları ve yüzdeleri verilmiştir.

Çizelge 4.1. Farklı doğal afetlerde hasar gören konut sayıları (Pampal ve Özmen, 2007)

Doğal Afet Türü	Yıkılan Konut Sayısı	Yüzde (%)
Deprem	495000	76
Heyelan	63000	10
Sel	61000	9
Kaya düşmesi	26500	4
Çığ	5154	1

İstatistiklere göre dünyada her yıl 500 bine yakın deprem meydana gelmekte, bunlardan sadece %20’si insanlar tarafından hissedilebilmekte ve bunların da binde biri yıkıcı hasarlara neden olmaktadır (AFAD, 2018). Depremler ekonomik olarak milyonlarca kayba sebebiyet verirken yılda ortalama 10 bin insan deprem nedeniyle hayatını kaybetmektedir. Dünya üzerinde ekonomik anlamda en büyük kayba neden olan deprem, 2011’de Japonya’da meydana gelen 9,1 büyüklüğündeki depremdir ki söz konusu deprem 38,75 milyar dolarlık ekonomik kayıp oluşturmuştur (Yılmaz, 2019). Türkiye özelinde her yıl gayri safi milli hasılanın yaklaşık %1’i deprem nedeniyle oluşan masraflara harcanmaktadır. Ayrıca AFAD verilerine göre doğal afetler dolayısıyla verilen can kayıplarının yaklaşık %60’ı deprem kaynaklı olmaktadır (AFAD, 2020). Sadece 2020 yılında meydana gelen doğa kaynaklı olayların istatistiklerini sunan, 29 Haziran 2021 tarihinde yayınlanan AFAD raporunda yine en çok deprem afeti ile karşılaşıldığı gözler önüne serilmektedir. Şekil 4.1’de söz konusu doğa olaylarının miktarları verilmiştir.



Şekil 4.1. 2020 yılında meydana gelen doğa kaynaklı olayların dağılımı (AFAD, 2021)


Depremler ortaya çıkış nedenlerine göre üçe ayrılmaktadır;

- Tektonik depremler
- Volkanik depremler
- Çöküntü depremleri

Yerkabuğunun altında bulunan magma tabakasının yeryüzüne volkanlar aracılığıyla çıkması sırasında oluşan fiziksel ve kimyasal olaylar nedeniyle ortaya çıkan patlamalar volkanik depremlere neden olurken, vahşi sulama vb. nedenlerden dolayı yeraltı sularının fazlaca çekilmesi sonucu oluşan boşlukların üzerindeki tavan bloğunun bir anda göçmesi çöküntü depremlerine neden olmaktadır.

Dünyada gerçekleşen depremlerin %90'ı tektonik kaynaklı oluşurken, Türkiye özelinde de gerçekleşen depremlerin neredeyse hepsi tektonik nedenlerden dolayı meydana gelmektedir. Ülkemizin yüzölçümünün yaklaşık %92'si aktif fay hatları üzerinde bulunmakta ve nüfusumuzun ise yaklaşık %95'i bu topraklar üzerinde yaşamaktadır (Yılmaz, 2019). Bununla birlikte sanayi varlığımızın %97'si, barajlar gibi temel altyapı tesislerinin %90'ı fay hatlarının üzerindedir (Karaesmen, 2002).

Ülkemizin en aktif deprem kuşaklarından biri olan Akdeniz-Alp-Himalaya deprem kuşağında bulunması, deprem afetini bizler için acı bir gerçek haline getirmiştir. İstatistiki olarak Türkiye'de beş yılda bir kez yıkıcı depremler meydana gelmektedir (AFAD, 2020). Şekil 4.2'de 01/01/2019 tarihinde yürürlüğe giren Türkiye Deprem Tehlike Haritası verilmiştir.




Şekil 4.2. Türkiye deprem tehlike haritası (URL 16)

Ülkemizde 1900’lü yıllardan bu yana sayısız deprem meydana gelmiştir. Bunların en büyüğü $M_w = 7,9$ olan Erzincan depremidir. Çizelge 4.2’de Türkiye’de meydana gelen büyük depremlerde verilen can ve mal kayıpları istatistikleri sunulmuştur.

Çizelge 4.2. Türkiye’de meydana gelen büyük depremlerin istatistikleri (Pampal ve Özmen, 2007)

Yer	Tarih	Büyükölük (M_w)	Ölü Sayısı	Ağır Hasarlı Bina Sayısı
Malazgirt	1903	6,7	2626	12000
Mürefte	1912	7,3	216	15000
Hakkari	1930	7,2	2514	3000
Erzincan	1939	7,9	32962	116720
Niksar-Erbaa	1942	7,0	3000	32000
Adapazarı-Hendek	1943	6,6	336	2240
Tosya-Ladik	1943	7,2	4000	40000
Bolu-Gerede	1944	7,2	3959	20865
Karlıova	1949	7,0	450	3500
Yenice-Gönen	1953	7,4	265	6750
Gediz	1970	7,2	1086	19291
Bingöl	1971	6,7	878	9111
Lice	1975	6,9	2385	8149
Çaldıran-Muradiye	1976	7,2	3840	9232
Erzurum	1983	6,8	1155	3241
Erzincan	1992	6,8	653	8057
Kocaeli-Gölcük	1999	7,4	17127	73342
Bolu-Düzce	1999	7,2	845	35519
Bingöl	2003	6,4	176	6000
Van	2011	7,2	644	2262
İstanbul	2019	5,8	1	62
Elazığ	2020	6,8	41	1569
İzmir	2020	6,6	116	475

AFAD’ın resmi verilerine göre aletsel dönem olarak adlandırdığımız 121 yıllık dönemde $M_w \geq 5$ büyüklüğünde 1796 deprem meydana gelmiştir. Şekil 4.3’te verilen grafik depremlerin yıllara göre dağılımını göstermektedir.




Şekil 4.3. 2009-2019 yılları arası meydana gelen deprem sayıları (AFAD, 2020)

4.1. Deprem Sonrası Betonarme Binalarda Oluşan Hasarlar

Deprem, çeşitli nedenlerden dolayı ortaya çıkan enerjinin birtakım dalga hareketleriyle titreşimsel şekilde yeryüzüne ulaşması hadisesidir. İnşa edilen tüm yapıların bu titreşim hareketlerinin yarattığı sarsıntılara ve deformasyonlara uyum sağlayabilmesi gerekir. Söz konusu uyum kabiliyetine “yapıların depremsel davranışı” adı verilmektedir. Yapılar ile üzerine inşa edildikleri zemin birbirinden ayrı birer kitle olduğundan yapıda oluşacak atalet kuvvetleri zemin hareketlerinin zıt yönünde oluşmaktadır ve bu atalet kuvvetleri yapılarda ciddi hasarlara neden olmaktadır (Tuna, 2000). Bir titreşim hareketine maruz kalan yapıda iki ana zorlanma riski söz konusudur. Bunlardan ilki taşıyıcı sistemin bazı kesitlerinin çok fazla zorlanması yani malzemenin tölere edebileceği eğilme mukavemetinden, eksenel dayanımından, kayma mukavemetinden birinin ya da birden fazlasının sınırlarının aşılmasıdır. Bu durumda yapıda kısmi veya tamamen çökmeler meydana gelebilmektedir. Bir diğer zorlanma riski ise yapıda meydana gelen deformasyonların fazlalığıdır. Çok fazla deformasyona uğramış yapı depremin ardından tamamen çökmeyebilir ancak dönme veya yanal ötelenmeler o kadar fazladır ki yapı kullanılmayacak hale gelmiştir. Tüm bu bilgiler ışığında

söylenebilir ki tasarımcılar tasarladıkları yapıda herhangi bir deprem sırasında küçük çatlaklar haricinde yapısal hasar oluşmamasına, mukavemetlerin sınır değerlere ulaşmamasına, taşıyıcı elemanlarda ciddi kırılmalar veya göçmeler oluşmamasına özen göstererek hesaplamalarını büyük bir özveriyle yapmalıdır (Karaesmen, 2002).


Depreme dayanıklı bir yapı tasarlamak için başlıca dikkat edilmesi gereken konu sünekliktir. Herhangi bir deprem yükü altında lineer elastik sınır aşıldığında yapı elemanının taşıma kapasitesinde ciddi bir düşüş olmadan büyük deplasmanlar yapabilmesi süneklik kavramının tanımıdır. Sünek yapılar, deprem dolayısıyla ortaya çıkan enerjiyi sönümleyerek yapının göçme durumuna ulaşmasını engelleyebilmektedir. Bu da yapının hem ekonomik hem de güvenilir olmasına neden olmaktadır. Şekil 4.4'te sünek ve sünek olmayan yapı elemanlarının kuvvet-yer değiştirme grafiklerine yer verilmiştir.




Şekil 4.4. Sünek ve sünek olmayan yapı elemanlarının kuvvet-yer değiştirme grafiği (Şahbaz, 2005)

Şekil 4.4'te verilmiş olan grafikten de anlaşılacağı gibi sünek davranış gösteren yapı elemanları sünek davranış göstermeyen yapı elemanlarına nazaran daha fazla deprem kuvvetine daha fazla yer değiştirme hareketi yaparak mukavemet gösterebilmektedir. Sünek davranış gösteren ve göstermeyen elemanlar arasında yapılabilecek bir diğer kıyaslama yer değiştirme-yük taşıma kapasitesi özellikleridir. Şekil 4.5 ve Şekil 4.6'da verilen grafiklerde I numaralı bölge beton yüzeyi üzerinde genişliği 0,2 mm'den az çatlakların görüldüğü, II numaralı bölge genişliği 0,2 mm ila 1 mm arasında değişen gözle net şekilde görülebilen çatlakların görüldüğü bölgedir. III

numaralı bölge genişliği 1 mm ila 2 mm arasında değişen çatlakların ve kabuk beton dökülmesinin görüldüğü, IV numaralı bölge 2 mm'den geniş çatlakların ve beton ezilmesinin görüldüğü, V numaralı bölge ise donatı burkulmasının ve çekirdek beton çatlamlarının görüldüğü bölgedir (Nakano ve ark, 2004).




Şekil 4.5. Sünek yapı elemanlarının yük taşıma kapasitesi-yer değiştirme grafiği (Nakano ve ark, 2004)



Şekil 4.6. Sünek olmayan yapı elemanlarının yük taşıma kapasitesi-yer değiştirme grafiği (Nakano ve ark, 2004)

Sünek davranışa sahip yapı elemanlarının kesit hasar seviyeleri Şekil 4.7’de verilen grafikte gösterilmiştir.



Şekil 4.7. TBDY-2018 Kesit hasar bölgeleri

TBDY-2018’de sünek elemanların kesit hasar seviyeleri sınırlı hasar (SH), kontrollü hasar (KH) ve göçme önlenmesi (GÖ) olmak üzere üç sınırdan incelenmektedir. SH düzeyi, hasarın sınırlı düzeyde kaldığı ve ihmal edilebilir olduğu; KH düzeyi taşıyıcı elemanlarda çoğunlukla onarılabilir hasarların görüldüğü; GÖ düzeyi ise ileri düzey hasarın olduğu çökme öncesi durumu anlatmaktadır.

Deprem yükleri yapılara etkiyen yanal yüklerden biridir ve ciddi hasarlara neden olmaktadır. Yapıların kalitesi, üzerine inşa edildikleri zeminin cinsi ve durumu, aldıkları deprem yüklerinin karakteristikleri ve sahip oldukları taşıyıcı sistem deprem davranışlarına etki eden parametreleri oluşturmaktadır.

Depreme dayanıklı yapı tasarımında diğer ülkelerdeki gibi ülkemizde de temel tasarım felsefesi geçerlidir. Yer kabuğunda sık sık meydana gelen küçük büyüklükteki depremlerde yapıların elastik bölgede kalmaları, orta büyüklükteki depremlerde yapıların yine elastik bölgeyi aşmamaları aldıkları hasarların ise küçük ve onarılabilir olması, çok yüksek büyüklüklerdeki depremlerde yapının can kaybına neden olmayacak şekilde hasar alması beklenmektedir (Şahbaz, 2005). Yeterli dayanım, yanal rijitlik ve sünek davranış kriterleri depreme dayanıklı bir yapı inşa etmek için gerekli koşullardır (Çırak, 2011).

Burulma, en temel anlamı ile yapıda bulunan kütle ve rijitlik merkezinin çakışmamasıdır. Kütle merkezi, geometrik merkez olarak düşünülebilirken rijitlik merkezi perde ve kolonlara gelen kesme kuvvetlerinin bileşkesinin geçtiği nokta olarak tanımlanmaktadır. Yapılarda söz konusu iki noktanın birbiri ile çakışması gerekmektedir. Çakışmadığı durumlarda dönme veya ötelenme gibi durumlar oluşmaktadır ve buna eksantrisite denmektedir. Eksantrisite, yapının deprem kuvvetlerine maruz kaldığında burulmasına ve ciddi hasar almasına neden olmaktadır (Güney, 2012). Sünek olmayan özellikle orta yaşlı yapılarda rijit kolon ve perdeler deprem yükleri altında burulma nedeniyle çökme tehlikesi ile karşı karşıya kalmaktadır (Yılmaz, 2019).

Bir diğer düzensizlik durumu olan döşeme süreksizliği, yapının herhangi bir katındaki döşemede bulunan boşluk alanları toplamının (asansör ve merdiven boşlukları dahil) o katın brüt alanının üçte birinden fazla olması halinde ortaya çıkmaktadır (TBDY, 2018). Söz konusu boşluklar, yapının rijit davranmasını engellemekte, deprem anında aşırı deplasmanlar oluşmasına neden olmaktadır.

Yapının kullanım alanını artırma isteğinden doğan kusurlardan biri çıkıntılı yapılardır. TBDY-2018’de planda çıkıntılar bulunması olarak adlandırılan bu durum, deprem yüklerinin olması gerektiği gibi iletilmesini engelleyerek yapıda burulmaya neden olabilmektedir. Bu tür düzensizlikten kaçınmak için yapılara deprem derzi bırakılabilir (Güney, 2012).

Betonarme binalarda yine kullanım alanını genişletmek veya buna ek olarak estetik kaygılar dolayısıyla kolonlar kirişlere göre daha küçük boyutlarda yapılabilir. Ancak söz konusu durum yapının yük taşıma kapasitesini önemli derecede etkilemekte, dinamik bir yükleme olan deprem yüklerinin altında kirişlerin elastik kalmasına kolonların ise kesme veya sıkıştırma etkilerinden muzdarip olmasına neden olmaktadır. Bu yapıların diğerlerine göre daha yıkıcı hasarlara uğrayabildiği görülmektedir (Arslan ve Korkmaz, 2007). Bu nedenle taşıyıcı sistem elemanlarından kolon kapasitelerinin kiriş kapasitelerinden en az %20 daha fazla olması gerekmektedir (Işık ve Özdemir, 2016).

Ülkemizde mimari ve ekonomik kaygılar nedeniyle oluşan bitişik nizam yapılar deprem sırasında tehlike oluşturabilecek bir diğer kusurdur. Birbirinden farklı kat yüksekliklerine sahip bitişik nizam olarak inşa edilmiş iki binada rastlanan, deprem sırasında farklı periyotlara sahip bu iki binanın birbiri ile çarpışması sonucu oluşan çekiçleme etkisi ciddi hasarlara neden olabilmektedir (Karaesmen, 2002).

TBDY-2018’de bahsedilen düzensizlik durumlarından diğeri zayıf katlardır. Betonarme binalarda yapısal olmayan eleman olarak geçmesine rağmen dolgu duvarlar yapılara etkiyen yatay deplasmanların bir kısmını karşılamakta ve yapının dayanımına katkı sağlamaktadır. Bazı binalarda zemin katların işyeri olarak kullanılması nedeniyle dolgu duvar yerine cam kullanılmakta ve bu uygulama söz konusu katın diğer katlara nispeten daha az rijit davranmasına neden olmaktadır. Bu nedenle deprem yükleri bu katlarda hasara yol açmaktadır (Yücel, 2012). Zayıf katta olduğu gibi işyeri olarak kullanılan zemin katların diğer katlara nispeten yüksekliğinin daha fazla olması durumunda oluşan diğer bir düzensizlik durumu olan yumuşak katların, yanal deprem kuvvetlerinin etkisinde diğerlerine göre daha fazla ötelenerek olası bir deprem sırasında hasar alması muhtemeldir.

TBDY-2018’de işlenen diğer bir düzensizlik durumu düşey taşıyıcı eleman süreksizliğidir. Bazı yapılarda kolonların en alt kata kadar inmediği, dolayısıyla kirişlere veya guseli kolonlara oturtulduğu; perdelerin en alt kadar devam etmeyip, kirişlere veya kolonlara oturtulduğu gözlemlenmektedir. Bu durum, deprem yüklerinin düzgün olarak iletilmemesine ve hasara yol açmasına neden olmaktadır. Bazı yapıların ise köşelerinde bulunan salonlarda tasarımcılar, mimarlar ya da yapı sahipleri sarkan bir giriş istemeyebilirler. Bu durumda köşeye yapılan kolon hiçbir kirişle birleştirilemez. Köşe kolon kirişlerden ziyade ince bir döşeme ile birleştiğinden dolayı ağır momentlere maruz kalmaktadır. Yapı sadece düşey yüklerin atındayken bile tehlikededir ki yatay yükler yapıya tesir ettiğinde köşe kolon uçları mafsallaşmakta, yapı göçme seviyesine ulaşmaktadır (URL 17).

Özellikle bodrum ve giriş katlarda zeminde bulunan kot farkından dolayı bazı kolonların diğerlerine göre daha kısa olarak tasarlanması ve şerit pencere gibi uygulamalar kısa kolon düzensizliğini oluşturmaktadır. Kolon boyu kısaldıkça moment kolu kısalmır ve eğilme rijitliği artar. Söz konusu kısa kolonlar diğer kolonlara kıyasla daha fazla kesme kuvveti alacağından deprem sırasında ağır hasarlara yol açmaktadır (Karaesmen, 2002).

Kolon etriyelerinin kolon-kiriş birleşim bölgelerinde devam ettirilmemesi sorunu ülkemizde 2000’li yıllarda önce çokça rastlanan, 2000’li yıllardan sonra da azımsanmayacak miktarda betonarme yapılarda görülen bir kusurdur. Söz konusu durumda betonarme yapı kolon-kiriş bağlantı bölgelerinden ağır hasar almakta ve deprem yüklerini karşılayabilecek perde duvar olmaması durumunda göçme durumuna

geçebilmektedir. Aynı zamanda yine bu durumda kolon, kiriş altından sıyrılarak bütünlük bozulmakta ve yine yapı göçme durumuna erişebilmektedir (Bakırcı Er ve ark, 2014).

Yapıların planlarında bulunan düzensiz bölme duvarlar ve her bölme duvar altına kiriş yapma, kullanım alanını artırma gibi istekler nedeniyle yapılan saplama kirişler deprem yükü taşıma açısından yapıyı kötü etkilemektedir. Kirişlerin her iki ucu kolonlara oturmalı ve döşemelerden gelen yükleri kolonlara iletmelidir. Ancak saplama kiriş uygulamasında kiriş kirişe oturmakta ve saplama kirişi taşıyan diğer kirişte oluşan moment ve kesme kuvvetleri nispeten daha fazla oluşmakta, yapı bu noktalardan hasar almaktadır.

Betonarme binalarda deprem sırasında tehlike arz eden kusurların bir kısmı işçilik ve tasarım kaynaklıdır. Bunlardan ilki filiz boylarının yetersizliğidir. Kenetlenme bölgelerinde yetersiz donatı kullanılması bu bölgelere etki eden ek kuvvetlere karşı yapısal elemanın mukavemet gösterememesine ve bu bölgelerden hasar almasına neden olmaktadır (Özmen ve ark, 2015). Bir diğer ve en çok rastlanan işçilik ve tasarım kusurlarından biri yetersiz etriye kullanımıdır. Bilindiği üzere etriye yapılara etkileyen kesme kuvvetlerini taşımakta, yanal yükleri karşılamakta ve donatıların burkulmasını önlemektedir. Özellikle kolon-kiriş birleşim bölgelerine yakın yerlerde yani kolon ve kirişlerin uç bölgelerinde etriyelerin daha sık yerleştirilmesi buralarda mafsallaşmaya neden olabilecek yanal deprem yüklerinin daha fazla sönümlenmesine ve yapının sünekliğinin artırılmasına katkı sağlamaktadır (Karaesmen, 2002). Üçüncü işçilik kusuru betonarme yapılarda kullanılan betonun dökümü aşamasında işlemin kesilmesi durumunda ortaya çıkan, estetik olarak kötü görünümün yanı sıra yapısal elemanların eğilme kapasiteleri ve moment taşıma kapasitelerini önemli derecede azaltan soğuk derzlerdir. Bir diğer işçilik kusuru betonun yerine yerleştirilmesi işleminde yeterli özen gösterilmemesi sonucu oluşan segregasyonlardır. Segregasyon nedeniyle dayanımı düşen beton, deprem yükleri altında hasar almaya elverişlidir. Beton yerleştirip sıkıştırıldıktan sonra kür işlemi başlamaktadır. Düzenli bakımı ve kür işlemi yapılmayan betonların bakım işlemi yapılanlara nispeten dayanımlarından ciddi düşüşler yaşandığı gözlemlenmiştir. İşçilik ve tasarım kusurlarının içinde kullanımdan kaynaklı kolon veya kirişlerin içerisinden tesisat boruları geçirilmesi kusuru sayılabilir. Söz konusu boruların kiriş çekme bölgesinden geçmesi, betonarme elemanın karakteristik özelliklerini (rijitlik, eğilme, süneklik) kaybetmesine neden olmaktadır. (Kumbasaroğlu ve Korkmaz, 2020). Bu durumda meydana gelebilecek olası bir depremde yapının hasar alması kaçınılmazdır.

Hazır beton kullanımının ülkemizde oldukça yaygınlaşmasına rağmen hala bazı şantiyelerde yerinde dökme denilen göz kararı malzemelerle karılan betonlar kullanılmaktadır. Söz konusu yerinde dökme uygulaması yeterli dayanımda beton üretilmesine olanak sağlamadığından deprem gibi unsurlara gerek kalmadan yapılar kendiliğinden göçebilmektedir. Bunun yanında ülkemizde önceden inşa edilmiş yapılarda kullanılan betonlardan numune alındığında yuvarlak yüzeyle, beton üretimine uygun olmayan çakıl taşlarının, yetersiz granülometriye neden olabilecek büyüklükte taşların, hatta denize kıyısı bulunan şehirlerde deniz kumu kullanılmasından kaynaklanan deniz kabuklarının kullanıldığı görülmüştür. Agregaların uygun granülometride olması betonun geçirimsizliğinin ve yoğunluğunun artmasını sağlamaktadır (Yılmaz, 2019). Kalitesiz malzemeye verilebilecek bir diğer örnek yine eskiden inşa edilmiş yapılarda gözlemlenen nervürsüz donatılardır. Donatılar üzerinde bulunan nervürler beton ile arasında bulunan aderansı artırarak donatı ile betonun beraber çalışmasını sağlamakta, iki malzemenin birbirinden sıyrılmasını engellemektedir. Tüm bu işçilik ve tasarım veya kullanım kaynaklı kusurlar, olası bir depremde yapıların ciddi derecede hasar almasına neden olmaktadır.

4.2. Betonarme Yapı Elemanlarının Deprem Davranışları


Betonarme yapılarda yatay ve düşey taşıyıcı elemanlar bulunmaktadır. Yatay taşıyıcı elemanlara kirişler ve döşemeler, düşey taşıyıcı elemanlara kolon ve perdeler örnek gösterilebilmektedir. Çalışmanın bu bölümünde depremler sırasında oluşan yapı hasarları eleman bazında incelenecektir. Depremler sırasında yapılarda oluşan hasarların en büyük belirleyicisi yapı elemanlarında gözlenen çatlaklardır. Bu çatlakların konumu, genişliği, oluşum şekli hasar tespit çalışması yapan araştırmacılara yapı hakkında önemli ipuçları vermektedir. Beton basınç dayanımı oldukça yüksek ancak çekme dayanımı düşük bir yapı malzemesidir. Yapıdaki çekme gerilmelerini karşılamak amacıyla betonun içerisine donatılar yerleştirilmektedir. Betonun en dış liflerindeki çekme birim uzaması 0,0001 ila 0,00015 cm uzunluğuna ulaştığında betonda çatlaklar oluşmaya başlamaktadır. Donatılar betonda oluşan çatlakları önlemez ancak, çatlak genişliklerinin büyümesini engeller. Betonda çatlakların görülmesi oldukça doğaldır. Söz konusu çatlakların genişliği 1-2 mm arasında iken donatı akmıştır ve yapı ağır hasarlıdır tanısı koyulabilmektedir (Tan, 2000; Mertol, 2002).

4.2.1. Kolon hasarları

Deprem sırasında kesme, burulma, eğilme, basınç gibi etkilerden bir veya birkaç tanesi eş zamanlı olarak kolonlarda hasarlara sebep olabilmektedir (Yüksel, 2008). Bunlara ek olarak narin kolonlarda burkulma hasarı da görülmektedir. Kolonlarda görülen deprem hasarları yapının kullanım durumu hakkında araştırmacılara önemli ipuçları vermektedir.

4.2.1.1. Kolonlarda eğilme çatlakları

Eğilme momentlerinin oluşturduğu hasarlara eğilme hasarı adı verilmektedir. Eğilme hasarları kolon eksenine dik şekilde meydana gelmektedir. Donatının aktığını gösteren bu tür hasarlar çekme bölgelerinde oluşmaktadır. Şekil 4.8’de kolonlarda oluşan eğilme çatlaklarına örnek gösterilmiştir.




Şekil 4.8. Kolonlarda meydana gelen eğilme çatlaklarının temsili gösterimi

4.2.1.2. Kolonlarda kesme çatlakları

Bilindiği üzere taşıyıcı elemanlara gelen kesme kuvvetlerini karşılamak amacıyla etriyeler kullanılmaktadır. Ancak etriyelerin düzgün ve yeterli kullanımı şantiyelerde

ihmal edilen hususlardan biri olmuştur. Kolonlarda etriyeler yanal deprem ve rüzgar yüklerini karşılamakta ve donatıların burkulmasını engellemektedir. Yeterli aralıklarda ve yeterli sayıda kullanılmadıkları takdirde kolonlarda kesme çatlakları oluşmaktadır. Eğer kolonda yeterli sayıda etriye bulunmuyor ise ani ve gevrek kırılmalar kaçınılmazdır. Kolonlarda derin kesme çatlakları görülüyor ise yapının ciddi hasar aldığı söylenebilir. Kesme çatlakları 45° açıya sahip diyagonal çatlaklardır. Bazı durumlarda kesme çatlakları “x” şeklinde de oluşabilmektedir. Kolona etkiyen kesme kuvvetleri arttığında kolonlarda ileri derecede kesme kırılmaları gözlenebilmektedir. Şekil 4.9’da kolonlarda oluşan kesme çatlaklarına ve ileri derecede kesme kırılmalarına örnek gösterilmiştir. Şekil 4.10’da kesme çatlağı oluşmuş bir kolon görüntüsü verilmiştir.




Şekil 4.9. Kolonlarda meydana gelen kesme çatlaklarının temsili gösterimi (a), ileri derecede kesme kırılmasının temsili gösterimi (b)



Şekil 4.10. Kesme çatlağı oluşmuş bir kolon

Bazı durumlarda kolonlarda eğilme ve kesme hasarları aynı anda oluşabilmektedir. Şekil 4.11’de kesme ve eğilme hasarı oluşmuş kolon gösterilmiştir. Şekil 4.12’de eğilme ve kesme etkilerinin aynı anda etki ettiği kolonda meydana gelen hasar gösterilmiştir.




Şekil 4.11. Kolonlarda kesme ve eğilme çatlaklarının aynı anda oluşmasının temsili gösterimi



Şekil 4.12. Kesme ve eğilme etkileri altında hasar almış kolon (Çırak, 2011)

4.2.1.3. Kolonlarda basınç çatlakları

Bir diğer kolon hasarı basınç çatlaklarıdır. Basınç çatlakları, kolon eksenine paralel yönde kolon uç bölgelerinde oluşan çatlaklardır. Kolonlara etkiyen yük, taşıma kapasitesinin %50'sini aştığı zaman kolonlarda basınç hasarları meydana gelmektedir. Basınç hasarları gevrek ve ani kırılmalara neden olmaktadır (Güney, 2012). Donatı akmadan betonda ezilmeler başlar. Beton basınç dayanımının düşük olduğu durumlarda oluşmaktadır (Yılmaz ve Umu). Şekil 4.13'te basınç çatlaklarına ve ileri derecede basınç etkisine maruz kalan kolonda görülen basınç kırılmaları ve donatı burkulmaları gösterilmiştir. Şekil 4.14'te ise basınç kırılması meydana gelmiş bir kolon görüntüsü verilmiştir.




Şekil 4.13. Kolonlarda meydana gelen basınç çatlaklarının (a), basınç kırılmalarının ve donatı burkulmasının temsili gösterimi (b)



Şekil 4.14. Basınç kırılması meydana gelmiş bir kolon (Yılmaz ve Umu)

4.2.1.4. Kolonlarda burulma çatlakları

Son olarak kolonlarda meydana gelen diğer hasar türü burulma hasarlarıdır. Burulma hasarını diğer hasarlardan ayırt edebilmek için kolonların ortak kenara sahip yüzeylerine bakılması gerekir. Kolonun birbirine bitişik iki kenarında kesilmeden devam eden çatlağın bulunması burulma etkisinin meydana geldiğini göstermektedir (Güney, 2012). Şekil 4.15'te kolonlarda meydana gelen burulma çatlağına örnek gösterilmiştir. Şekil 4.16'da burulma hasarı meydana gelmiş bir kolon görüntüsü verilmiştir.



Şekil 4.15. Kolonlarda meydana gelen burulma çatlağının temsili gösterimi




Şekil 4.16. Burulma hasarı oluşmuş bir yapı (Yılmaz ve Umu)

4.2.2. Perde hasarları

Betonarme yapılarda perde elemanlar oldukça önemlidir. Deprem, rüzgar gibi yatay yüklere karşı yapının mukavemet sağlamasına en çok katkı sağlayan yapısal eleman perde duvarlardır. Perdelerde deprem sırasında eğilme ve kesme hasarları meydana gelmektedir. Kat adedi ve kat yükseklikleri perde duvarların alacağı hasarlar için belirleyicidir. Örneğin az kat sayısına sahip betonarme yapılarda bulunan perde duvarlar kesme hasarına maruz kalırken nispeten daha fazla kat sayısına sahip betonarme yapılarda bulunan perde duvarlar eğilme hasarlarına maruz kalmaktadır. Bu durumun nedeni düşük yükseklikteki yapılarda perdelerle etkiyen eğilme momentlerinin, perdenin taşıyabileceği eğilme momentlerinden daha az olmasıdır (Yılmaz ve Umu).

4.2.2.1. Perdelerde eğilme çatlakları


Eğilme çatlakları, kolonlarda olduğu gibi perde düzlemine dik şekilde oluşurlar. Pencere veya kapı boşluğu bulunmayan perdelerde ve yükseklikleri fazla betonarme binalarda zemin ve zemine yakın katlarda bulunan perdelerde bu tür çatlaklar gözlemlenmektedir (Yüksel, 2008). Eğilme çatlakları boyunca donatıların akması halinde perdelerde eğilme kırılması durumu yaşanabilmektedir. Perdelerde görülen eğilme çatlaklarına Şekil 4.17’de örnek gösterilmiştir.



Şekil 4.17. Perdelerde deprem sırasında oluşan eğilme çatlakları (Tan, 2000)

4.2.2.2. Perdelerde kesme çatlakları

Perde elemanlarda gözlenen diğer hasar türü kesme çatlaklarıdır. Kolonlarda olduğu gibi 45° açıyla diyagonal şekilde oluşan kesme çatlakları, perdeye etkiyen düşey yüklerin artması sonucu daha dik şekilde de oluşabilmektedir. Kolonlarda olduğu gibi uygun olmayan aralıklarda ve yetersiz etriye kullanımı, uygun olmayan boyutlarda perde yapılması kesme çatlaklarının ilerleyip kesme kırıklarının oluşmasına neden olmaktadır. Perdelerde en çok görülen çatlaklar “x” şeklindeki kesme çatlaklarıdır. Bu tür çatlaklar eğilme çatlaklarının aksine az katlı betonarme yapılarda bulunan perde duvarlarda görülmektedir. Şekil 4.18’de betonarme perde duvarlarda meydana gelen kesme çatlakları gösterilmiş, Şekil 4.19’da ise kesme çatlakları oluşmuş bir perde görseli verilmiştir.



Şekil 4.18. Perde duvarlar meydana gelen kesme çatlaklarının temsili gösterimi

Betonarme yapılar tasarlanırken yapılacak olan perdeler simetrik olarak yerleştirilmelidir. Burulma düzensizliğinde bahsedilen rijitlik merkezini etkileyen en önemli yapısal eleman perde duvarlardır. Simetrik yapılmadıkları takdirde kütle ve rijitlik merkezinin çakışmamasına ve dolayısıyla burulma hasarının oluşmasına neden olmaktadır. Tek yönde perde duvarlar yapılmış bir yapıya zayıf yönden etkiyen deprem kuvvetleri perdelerin düğüm noktalarından hasar almasına sebep olmaktadır (Yılmaz ve Umu).




Şekil 4.19. Kesme çatlakları oluşmuş bir perde duvar (Yılmaz ve Umu)

4.2.3. Kiriş hasarları

Kirişlerde, kolonlarda olduğu gibi deprem sırasında eğilme, kesme ve burulma çatlakları meydana gelmektedir. Kirişlerde oluşan çatlaklar çok geniş olmadıkları sürece taşıyıcı sistemi çok fazla etkilememesine rağmen yine de kirişlerde oluşan çatlaklar kontrol altında tutulmalıdır (Çırak, 2011).

4.2.3.1. Kirişlerde eğilme çatlakları

Eğilme çatlakları, momentlerin fazla olduğu kiriş uçlarında oluşmaktadır. Kirişlerde meydana gelen eğilme çatlakları mesnet bölgelerine yaklaştıkça büyürse yapı elemanının ağır hasar aldığı söylenebilmektedir. Boyuna donatıların uygun miktarda veya çapta kullanılmamasından dolayı meydana gelen eğilme çatlakları, kiriş eksenine dik şekilde oluşmaktadır. Çalışmada daha önce bahsedilen saplama kiriş düzensizliklerinde tali kirişin saplandığı ana kiriş çok fazla eğilme momentlerine maruz kalacak ve üzerinde eğilme çatlakları oluşacaktır (Yılmaz ve Umu). Bir kirişte oluşan eğilme çatlakları, içerisinde bulunan donatıların aktığını göstermektedir (Çırak, 2011). Şekil 4.20’de kirişlerde meydana gelen eğilme çatlakları gösterilmiştir. Şekil 4.21’de ise eğilme çatlağı oluşmuş bir kiriş görüntüsü verilmiştir.



Şekil 4.20. Eğilme çatlakları oluşmuş bir kirişin temsili gösterimi


Nervürlü donatı kullanılarak imal edilmiş bir kirişte eğilme çatlakları sayıca fazladır fakat genişlikleri küçüktür. Buna karşın, nevürsüz donatı kullanılarak imal edilen bir kirişte eğilme çatlaklarının sayısı azalırken çatlak genişlikleri artar. Yapı elemanlarında meydana gelen eğilme çatlakları, elemanın eğilme rijitliğini %30 oranında azaltmaktadır (Mertol, 2002).



Şekil 4.21. Eğilme çatlakları meydana gelmiş bir kiriş

4.2.3.2. Kirişlerde kesme çatlakları

Yine etriye eksikliğinden kaynaklanan kesme çatlakları kirişlerde de meydana gelmektedir. Kolon ve perdelerde olduğu gibi kesme çatlakları 45° açıda sahip diyagonal çatlaklar olarak ayırt edilebilmektedir. Bu türde hasar mütemadiyen iki perde arasında mevcut olan bağ kiriş adı verilen kirişlerde “x” şeklinde oluşmaktadır (Yılmaz ve Umu). Şekil 4.22’de kirişlerde meydana gelen kesme çatlakları gösterilmiştir. Şekil 4.23’te kesme çatlakları meydana gelmiş bir kirişin görüntüsü verilmiştir.




Şekil 4.22. Kirişlerde meydana gelen kesme çatlaklarının temsili gösterimi



Şekil 4.23. Kesme çatlakları oluşmuş bir kiriş

4.2.3.3. Kirişlerde burulma çatlakları

Kolonlarda olduğu gibi kirişlerde de deprem sırasında burulma çatlakları görülebilmektedir. Birbirine bitişik üç ardışık kenarda devam eden çatlaklar kalan diğer kenarda da ezilmeler görülmesi burulma olayının gerçekleştiğini göstermektedir. Burulma çatlakları yapının burulma rijitliğini $1/10$ oranında azaltmaktadır (Çırak, 2011). Şekil 4.24'te kirişlerde meydana gelen burulma çatlakları gösterilmiştir.




Şekil 4.24. Kirişlerde oluşan burulma çatlaklarının temsili gösterimi

4.3. Yapısal Olmayan Elemanların Deprem Davranışı

Depremler sırasında betonarme yapılarda sıvalarda ve duvarlarda hasarlar gözlemlenebilmektedir. Söz konusu hasarlar, yapıya önemli derecede bir zarar vermemekle beraber depremin ardından yapılan tadilat çalışmalarıyla onarılabilmektedir.

4.3.1. Sıva çatlakları

Depremden kaynaklanan titreşimler, betonarme yapılarda ilk olarak sıva çatlaklarını oluşturmaktadır. Önce dolgu duvarların kirişlerle birleşiminde oluşmaya başlayan çatlaklar, hemen ardından kolonlar ile dolgu duvarlar arasında oluşmaktadır. Bu sıva çatlakları, taşıyıcı sisteme önemli derecede zarar vermemektedir (Yılmaz ve Umu). Şekil 4.25'te söz konusu çatlaklar gösterilmiştir. Şekil 4.26'da ise depremlerden sonra görülen dolgu duvar ile taşıyıcı sistem çerçevesi arasında oluşan çatlakların görüntüsü verilmiştir.




Şekil 4.25. Dolgu duvarlar ve taşıyıcı sistem çerçevesi arasında oluşan sıva çatlaklarının temsili gösterimi



Şekil 4.26. İzmir (Seferihisar) depremi sırasında betonarme yapıda görülen sıva çatlağı

Aynı zamanda V veya VI şiddetindeki depremler duvar içerisinde bulunan tesisat boşlukları boyunca da sıvada çatlaklar oluşturabilmektedir. Yapıda bulunan çatlaklar sıva çatlakları düzeyinde kalmış ise genelde taşıyıcı elemanlarında herhangi bir hasar gözlenmez (Tan, 2000). Şekil 4.27’de tesisat boşlukları boyunca oluşan çatlaklar gösterilmiştir. Şekil 4.28’de söz konusu tesisattan kaynaklanan duvar sıvası çatlaklarının görüntüsü verilmiştir.



Şekil 4.27. Tesisat boşlukları boyunca oluşan sıva çatlaklarının temsili gösterimi




Şekil 4.28. Tesisattan kaynaklanan duvar çatlakları

4.3.2. Duvar çatlakları

Duvarlarda oluşan hasarlar oluşum nedenlerine göre kendi içinde dörde ayrılmaktadır. Bunlar; deprem titreşimleri, temel oturması, aşırı sehim ve çerçeveden gelen yapay titreşimlerdir.

4.3.2.1. Deprem titreşimleri nedeniyle oluşan duvar çatlakları

Deprem şiddeti arttıkça dolgu duvarlarda çatlaklar oluşmaya başlamaktadır. Dolgu duvar çatlakları önce kiriş-duvar ve kolon-kiriş birleşim yerlerinden oluşmaya başlamaktadır. Şekil 4.29'da hafif dolgu duvar hasarı temsili şekilde gösterilmiştir. Şekil 4.30'da ise Elazığ (Sivrice) depreminden sonra gözlenen hafif duvar hasarı fotoğrafı verilmiştir.




Şekil 4.29. Deprem sırasında oluşan hafif dolgu duvar hasarının temsili gösterimi (Tan, 2000)



Şekil 4.30. Deprem sırasında oluşan hafif dolgu duvar hasarı

Daha şiddetli depremlerde dolgu duvarlarda oluşan çatlaklar çapraz veya “x” şeklinde gözlemlenmektedir. Şekil 4.31’de orta dereceli dolgu duvar hasarı temsili şekilde gösterilmiştir. Şekil 4.32’de ise İzmir (Seferihisar) depreminden sonra görülen orta dereceli dolgu duvar hasarı fotoğrafı verilmiştir.




Şekil 4.31. Deprem sırasında oluşan orta dereceli dolgu duvar hasarının temsili gösterimi



Şekil 4.32. Deprem sırasında oluşan orta dereceli dolgu duvar hasarı

Çok şiddetli depremlerde duvarlarda ileri düzeyde “x” şeklinde çatlaklar ve kırılmalar meydana gelir. Bu çatlak türü kalitesiz malzemeyle inşa edilmiş dolgu duvarlarda diğerlerine nispeten daha çok görülmektedir (Yüksel, 2008). Şekil 4.33’te bu şekildeki kırılmalara örnek gösterilmiştir.



Şekil 4.33. Deprem sırasında oluşan ağır dolgu duvar hasarı


Yüksek duvarların üst kısımlarında yıkılmalar gözlenebilmektedir. Kapı veya pencere boşluklarının köşe kısımlarında çatlaklar, kırılmalar oluşmaktadır. Şekil 4.34'te duvarlarda görülen “x” şeklindeki çatlakların görüntüsü verilmiştir. Dolgu duvarlarda şekildeki gibi ileri derecede hasar oluşmuşsa, yapının taşıyıcı sistem elemanlarında da hasar beklenir.



Şekil 4.34. Deprem titreşimleri dolayısıyla duvarlarda oluşan kırılmalar

4.3.2.2. Temel oturması nedeniyle oluşan duvar çatlakları


Yapılar, inşa edildikleri zemine üzerine aldıkları yükleri temel aracılığı ile aktarır. Temeller yapıdan gelen yükleri, zemine yayma suretiyle yapı güvenliğini sağlarlar. Yapı inşa edildiği anda nemli, doymuş ve kuru zeminlerde aniden oluşan oturmalar meydana gelmektedir. Ani oturmalar, zemindeki su içeriğinde herhangi bir değişiklik olmamaktadır. Ani oturmaların yanında yapılarda bazı durumlarda konsolidasyon denilen zamanla meydana gelen oturmalar da gözlemlenmektedir. Konsolidasyon oturmasında, zemindeki su ve hava ayrılarak daneler arasındaki boşluklar azalmakta ve oluşan bu boşluklardan dolayı dolgu duvarlarda hasarlar meydana gelmektedir. Temel oturması sebebiyle oluşan çatlaklar zemin katlardan üst katlara çıkıldıkça azalmaktadır (Şirin, 2006; URL 18). Şekil 4.35'te temel oturması nedeniyle oluşabilecek hasarlar gösterilmiştir.



Şekil 4.35. Temel oturması nedeniyle yapılarda oluşan çatlakların temsili gösterimi (Şirin, 2006)

4.3.2.3. Aşırı sehim nedeniyle oluşan duvar çatlakları

Yapıda oluşan sehimler dolgu duvarlarda hasarlara neden olmaktadır. Ülkemizde sıklıkla gözlenen konsol duvar çıkmalarında söz konusu çatlaklar meydana gelebilmektedir. Konsol duvarlarda sehim dolayısıyla oluşan çatlaklar yatay şekilde ve boydan boya oluşmaktadır. Komşu duvarlarda ise eğik çekme çatlaklarının görülme olasılığı yüksektir (URL 18). Şekil 4.36’da ağır konsol çıkmalar nedeniyle meydana gelen sehim ve dolayısıyla dolgu duvarlarda oluşan çatlakların temsili gösterimine yer verilmiştir.



Şekil 4.36. Aşırı sehim nedeniyle konsol çıkmalarda meydana gelen duvar çatlaklarının temsili gösterimi (Şirin, 2006)

4.3.2.4. Çerçeveden gelen titreşimler nedeniyle oluşan duvar çatlakları

Betonarme yapılarda, yapısal elemanların yeterli rijitlikte yapılmaması sonucu yapay titreşimlerden kaynaklı bu elemanlarda titreşim hareketleri oluşmaktadır. Çerçeveler arasında bulunan dolgu duvarlar da yapısal elemanlardan gelen titreşimlerin etkisiyle farklı periyotlarda titreşmeye başlamaktadır. Bu titreşimler sonucu dolgu duvarlarda çeşitli hasarlar gözlemlenebilmektedir. Bu tür hasarlara yapıların içerisinde bulunan ve sürekli çalışan makineler, yoldan geçen ağır vasıtalar ya da yapıya yakın konumda bulunan demiryollarından geçen metrolar neden olmaktadır (Şirin, 2006).

5. ANALİTİK ÇALIŞMA


YZ sistemlerindeki en önemli unsurun veridir. Özellikle DÖ modellerinde veri sayısı ve kalitesi arttıkça elde edilen başarı oranının da arttığı birçok çalışmada kanıtlanmıştır. Bu tez çalışmasında daha önce kullanılmamış bir veri seti oluşturulmuştur. Ülkemizde 2019 ve 2020 yıllarında meydana gelen $M_w \geq 5$ büyüklüğüne sahip İstanbul (Silivri), Elazığ (Sivrice) ve İzmir (Seferihisar) depremlerinin ardından betonarme yapılarda oluşan hasar görüntülerinden meydana gelen veri seti, oluşan hasarları yapısal eleman hasarları veya yapısal olmayan eleman hasarları şeklinde sınıflandırma yapmak üzere algoritmayı eğitmek ve test etmek için kullanılmıştır. Bu bölümde ilgili depremlerin özellikleri ve karakteristikleri, hasar görüntüleri ile ilgili elde edilen verilerin istatistikleri üzerinde durulmuş ve algoritmanın geliştirilmesi ayrıntılı şekilde açıklanmıştır.

5.1. Ülkemizde Yaşanan Son Depremler ve Oluşan Hasarların İncelenmesi

Ülkemizin üç aktif fay hattı üzerinde bulunması, bu bölgelerde yaşayan insanların her beş yılda bir yıkıcı depremlerle karşı karşıya kalmasına neden olmaktadır. Kaçınılmaz bir gerçek olan depremlerin zararlarından minimum düzeyde etkilenmek için deprem bilincinin özellikle fay hatları üzerinde bulunan bölgelerde yaşayan insanlara kazandırılmasının yanında burada inşa edilen yapıların depreme dayanıklı yapı tasarımı esasına uygun olarak tasarlanması gerekmektedir. Ülkemizde son yıllarda gerçekleşen depremler sonucunda betonarme yapılarda az, orta, ileri derecede hasarlar gözlemlenmiştir. İstanbul (Silivri), Elazığ (Sivrice) ve İzmir (Seferihisar) depremlerinin özellikleri ve bu depremlerde hasar alan betonarme yapılarda oluşan hasarlar incelenmiştir.


5.1.1. İstanbul (Silivri) Depremi

26 Eylül 2019 tarihinde saat 13.59'da İstanbul'un Silivri ilçesi açıklarında AFAD raporuna göre $M_w = 5,8$, Kandilli Rasathanesi'nin yayımladığı rapora göre $M_w = 5,7$ büyüklüğünde bir deprem meydana gelmiştir. Deprem odak derinliği AFAD tarafından 7 km olarak, Kandilli Rasathanesi tarafından ise 15 km olarak belirlenmiştir. Bu değerler meydana gelen depremin sığ depremler kategorisine girdiğini göstermektedir (AFAD,




Şekil 5.2. Bölgenin aleltsel dönem deprem aktivitesi (AFAD, 2019)

Deprem şiddeti AFAD ve Kandilli Rasathanesi tarafından VI olarak hesaplanmıştır. Şekil 5.3'te ise deprem ön hasar tahmin sistemi kullanılarak hesaplanmış depremin tahmini şiddet haritaları gösterilmiştir.



Şekil 5.3. AFAD tarafından hazırlanan tahmini şiddet haritası (a), Kandilli Rasathanesi tarafından hazırlanan tahmini şiddet haritası (b) (AFAD, 2020; KRDAE, 2020)


Deprem meydana geldikten sonra AFAD raporuna göre 27 Eylül 2019 tarihi, saat 07.40'a kadar $1,0 \leq M_w \leq 4,1$ büyüklükleri arasında toplam 150 artçı şok meydana



Şekil 5.5. 3408, 5906, 3412, 3407, 3405, 4132, 4138 istasyonlarından elde edilen veriler ile çizilmiş davranış spektrumu grafikleri ve DD-2, DD-3 deprem yer hareketi düzeyleri tasarım spektrumları (Zülfikar ve ark, 2020)

Depremi, İstanbul ilinin haricinde Kırklareli, Yalova, Bursa ve Kocaeli illerinde yaşayan insanlar ciddi derecede hissetmiştir. Yapılan çalışmalar ışığında depremin Kuzey Anadolu Fay Hattında gerçekleşen sağ yanal doğrultu atımlı hareketten kaynaklandığı ortaya çıkmıştır (Zülfikar ve ark, 2020). 1999 yılında yaşanan büyük Marmara Depreminden sonra meydana gelen en büyük deprem olması nedeniyle araştırmacılar açısından büyük önem taşımaktadır. Depremde hayatını kaybeden bir kişi göçük altında kalarak değil, deprem sırasında oluşan korkudan kalp krizi geçirerek vefat etmiştir. Aynı zamanda 43 kişi yaşanan panik ve korku nedeniyle yaralanmıştır (URL 19).

Depremi ardından yapılan hasar tespit çalışmalarında yapıların yapısal ve yapısal olmayan elemanlarında deprem titreşimleri nedeniyle gözlenen hasarların yanı sıra yapıların önemli bir kısmında deprem kaynaklı olmayan korozyon hasarı gözlemlenmiştir. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından yapılan hasar tespit çalışmasından elde edilen hasar dereceleri istatistikleri Şekil 5.6'da grafik şeklinde gösterilmiştir.



Şekil 5.6. İstanbul (Silivri) depreminde hasar alan betonarme yapıların hasar derecelerine göre dağılımı (URL 20)

Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından yapılan hasar tespit çalışmasından elde edilen istatistikler incelendiğinde 68 binada ağır hasar tespit edilmiştir. Deprem sırasında oluşan yatay yükler nedeniyle yapı elemanlarında hasarlar gözlemlenmiştir. Şekil 5.7’de İstanbul (Silivri) depremi sırasında hasar alan yapısal elemanların görüntülerine yer verilmiştir.




(a)



(b)

Şekil 5.7. İstanbul (Silivri) depreminde hasar alan kolon (a), İstanbul (Silivri) depreminde hasar alan kiriş (b)

Yapısal elemanların yanında yapısal olmayan elemanlarda da çeşitli hasarlar gözlemlenmiştir. Şekil 5.8’de İstanbul (Silivri) depremi sırasında oluşan yapısal olmayan hasarlara örnek gösterilmiştir.



Şekil 5.8. İstanbul (Silivri) depremi sırasında meydana gelen yapısal olmayan eleman hasarları

İstanbul (Silivri) depremi sonrası yapılan hasar tespit çalışmalarında en çok karşılaşılan kusur korozyon olmuştur. Korozyon, metal cisimlerin başka maddelerle elektrokimyasal veya kimyasal reaksiyona girerek bozulması olarak tanımlanabilmektedir. Betonarme yapılarda kiriş veya kolonların içerisinde bulunan donatılarda korozyon olduğu betonun şişip çatlamasından anlaşılabilmektedir (Yüzer, 2003). Donatıları dış etkilerden korumak amacıyla yapısal elemanlarda yeterli beton örtüsü olmalıdır. Yeterince pas payı bırakılmayan yapısal elemanlar hava ile hatta duruma göre suyla temas etmeye başlamakta ve korozyon oluşmaya başlamaktadır. Korozyon çoğu zaman çok dikkat edilmeyen bir kusur olmasına rağmen ileri derecede korozyona uğramış donatılarda kırılmalar, kopmalar hatta dokunulduğunda dağılmalar meydana gelmektedir. Özellikle 1999 İstanbul Depremi'nden önce denize kıyısı bulunan şehirlerde inşa edilen bazı yapılarda deniz suyu ve deniz kumu kullanılmış, bunların içerisinde bulunan tuz nedeniyle donatı korozyonu gerçekleşmiştir. Kolonlardaki donatı boyunca meydana gelen çatlaklar, kirişlerde yine donatı boyunca meydana gelen çatlaklar korozyon ihtimalini akıllara getirmektedir. Şekil 5.9'da korozyon hasarı görselleri verilmiştir.






Şekil 5.9. Korozyon hasarları


Korozyon bir deprem hasarı değildir. Ancak donatıları korozyona uğramış yapının kabuk betonu deprem titreşimleri ile elemandan ayrılmakta ve dökülmektedir. Bu nedenle depremden sonra dökülmeler meydana geldiğinden dolayı hasar deprem hasarıdır gibi yanlış değerlendirmelerde bulunulabilmektedir. İstanbul (Silivri) depreminden sonra binalarının hasar aldığı gerekçesiyle belediyelere ihbarda bulunan vatandaşların binaları incelendiğinde birçoğunun korozyon kaynaklı hasarlar olduğu gözlemlenmiştir.

5.1.2. Elazığ (Sivrice) Depremi

24 Ocak 2020 tarihinde saat 20.55'te meydana gelen ve AFAD verilerine göre $M_w = 6,8$ büyüklüğüne; Kandilli Rasathanesi verilerine göre ise $M_w = 6,6$ büyüklüğüne sahip olan deprem, başta Elazığ olmak üzere Doğu Anadolu, Karadeniz, Orta Anadolu ve Güney Doğu Anadolu bölgelerinde hissedilmiştir. Ölçülen deprem süresi 20,4 saniyedir. Deprem merkezi, Elazığ ilinin Sivrice ilçesine bağlı olan Çevrimtaş beldesi olmuştur (Şıkoğlu ve Güney, 2020). Depremin odak derinliği AFAD'a göre 8,06 km; Kandilli Rasathanesi'ne göre 5 km olarak ölçülmüştür ve bu değerler depremin sığ depremler




Deprem tahmini şiddeti AFAD tarafından IX, Kandilli Rasathanesi tarafından VII olarak belirlenmiştir. Şekil 5.12’de deprem tahmini şiddet haritaları verilmiştir.



Depremden sonra Kandilli Rasathanesi’ne göre $1,2 \leq M_w \leq 5,1$ arasında değişen 1185; AFAD’a göre $0,8 \leq M_w \leq 5,1$ büyüklükleri arasında 995 artçı deprem meydana

gelmiştir. Söz konusu artçı depremler 8 Şubat 2020 tarihine kadar devam etmiştir. Şekil 5.13'te artçı depremlerin haritası verilmiştir.




(a)


(b)

Şekil 5.13. AFAD raporuna göre artçı şokların haritası (a), Kandilli Rasathanesi'nin raporuna göre artçı şokların haritaları (AFAD, 2020; KRDAE, 2020)

2. dereceden deprem bölgesi olan Elazığ'da Sivrice depreminin ardından oluşan artçı şokların miktarının grafiği Şekil 5.14'te günlere göre artçı depremlerin dağılımı ise Şekil 5.15'te gösterilmiştir.



Şekil 5.14. Elazığ (Sivrice) depremi sonrası oluşan artçı depremlerin sayıları ve büyüklükleri (KRDAE, 2020)



Şekil 5.15. Günlere göre artçı deprem sayılarının dağılımı (KRDAE, 2020)


Elazığ ili, Kuzey Anadolu Fay hattı ile Doğu Anadolu Fay hattı arasında kalan depremselliği oldukça yüksek bir bölgede yer almaktadır. Sivrice depreminin Doğu Anadolu Fay Hattı'nda meydana gelen, sol yanal doğrultu atımlı bir deprem olduğu gözlemlenmiştir (Şıkoğlu ve Güney, 2020).

Elazığ ve çevre illerde bulunan ivmeölçerlerin beş tanesinde ölçülen değerler Çizelge 5.2'de gösterilmiştir.

Çizelge 5.2. Sivrice depremi anında ölçüm yapan beş istasyondan alınan bilgiler (AFAD, 2020)

İstasyon Kodu	İl	R _{epi} (km)	PGA (gal)
2308	Elazığ	24	292,77 (DB)
4404	Malatya	25	239,24 (DB)
0204	Adıyaman	37	110,11 (DB)
2301	Elazığ	36	140,73 (DB)
2302	Elazığ	53	33,97 (DB)


İstasyonlardan elde edilen bilgiler ışığında en yüksek ivme değerinin 2308 koduna sahip istasyondan alınan 292,77 gal ivme değeri olduğu anlaşılmaktadır. Söz konusu en yüksek ivme değeri doğu-batı yönlüdür. Doğan ve arkadaşlarının 2021 yılında Elazığ (Sivrice) depreminin ardından yaptıkları çalışmaya göre çizdikleri tasarım spektrum grafiği Şekil 5.16'da verilmiştir.



Şekil 5.16. Elazığ ili Sivrice ilçesindeki 2308 kodlu istasyon için ivme tepki spektrumlarının tasarım spektrumları (TDY-2007 ve TBDY-2018 için DD-2) ile karşılaştırılması (Doğan ve ark, 2021)

Söz konusu depremde 41 kişi hayatını kaybetmiş çok sayıda yapı hafif ya da ağır hasar almıştır, bunun yanında 45 kişi enkaz altından sağ olarak kurtarılmıştır. 41 ölümden 33'ü betonarme binalarda, kalan 8'i ise kırsal bölgelerde bulunan yığma yapılarda vuku bulmuştur (Bikçe ve Erdem, 2021). Elazığ ilinde yaşayan vatandaşların yaklaşık %13'ü bu depremten etkilenmiştir.

Şıkoğlu ve Güney'in 2020 yılında yaptıkları çalışmadaki istatistiki bilgilerden yola çıkarak Şekil 5.17'deki Elazığ'da bulunan binaların hasar durumlarına göre sınıflandırılması ile ilgili pasta dilimi grafik çizilmiştir.



Şekil 5.17. Elazığ'da bulunan binaların hasar tipi dağılımı (Şıkoğlu ve Güney, 2020)

Grafikten de anlaşılacağı gibi yıkılan ve acil yıkım kararı verilen binalar tüm binaların %3'ünü, ağır hasarlı binalar %17'sini, orta hasarlı binalar %10'unu ve az hasarlı binalar ise tüm binaların %70'ini oluşturmaktadır. Depremin ardından yapılan hasar tespit çalışmalarında taşıyıcı elemanlarda özellikle kiriş ve kolonlarda ciddi hasarlar gözlemlenmiştir.

Şekil 5.18'de Elazığ kentinde depremin ardından yıkılan binaların görüntülerine yer verilmiştir.




(a)



(b)


Şekil 5.18. Elazığ (Sivrice) depreminde yıkılan yapıların görüntüleri (a), (b)

Doğan ve ark. 2020 yılında meydana gelen Elazığ (Sivrice) depreminden hemen sonra yaptıkları hasar tespit çalışmasında, depremin merkez üssü olan Elazığ ilinde yıkılan, ciddi hasar alan betonarme binalar olduğunu; kırsal alanlarda özellikle Çevrimtaş ve Duygulu köylerinde yığma yapılarda ciddi hasarlar meydana geldiğini raporlamışlardır. Bunun yanında çalışmada, betonarme binalarda yapısal hasarların yanı sıra yapısal olmayan hasarların da oluştuğuna yer verilmiştir. Yapılan araştırmalar ışığında Elazığ kentinde bulunan betonarme binalardan bazılarının eski bazılarının ise nispeten yeni yapılar olduğu gözlemlenmiştir. Ülkemizde genel olarak yapı denetimi uygulamasının 1999 Marmara depreminden sonra 2000’li yıllarda uygulanmaya başlanmıştır. Buna rağmen alışkanlıklardan kurtulunmasının uzun zaman aldığını göz önünde bulundurulduğunda yapıların çoğunun denetimsiz ve kurlsız olarak inşa edildiği gerçeği ortaya çıkmaktadır. Araştırmacılar yıkılan veya ağır hasar alan binaların bu tarihten daha önce inşa edildiğini az hasar alan veya hiçbir hasar görmeyen yapıların ise nispeten daha yeni yapılar olduğunu gözlemlemişlerdir (Doğan ve ark, 2020). Şekil 5.19’da ağır hasar alan binaların yapım yıllarına göre dağılımı grafik şeklinde verilmiştir.




Şekil 5.19. Elazığ’da deprem sırasında ağır hasar alan yapıların inşa edildikleri yıllara göre dağılımı (FYHAG, 2020)

Fırat Üniversitesi’nde kurulan Yapısal Hasar Araştırma Grubu (FYHAG, 2020) Elazığ (Sivrice) depreminden sonra oluşan hasarları tasarımdan kaynaklanan ve yapımdan kaynaklanan olmak üzere ikiye ayırmıştır. Yaptıkları çalışmada kentte bulunan her bina için kat yükseklikleri, kolon-kiriş boyutları, inşa yılı, zemin koşulları ve oluşan düzensizlikler hakkında raporlar düzenlemişlerdir. Tasarımdan kaynaklı hasarları tespit edebilmek amacıyla binaların projelerine ulaşmaya çalışmışlar, bazıları hariç amaçlarına ulaşmışlardır. Projelerden yola çıkarak 2000’li yıllardan önce inşa edilmiş yapılarda kolon ve kirişlerden oluşan çerçeve sistemin kullanıldığı ancak depreme karşı asıl dayanımı sağlayan perdelerin kullanılmadığı görülmüştür. Birçoğunda da çerçevelerin yük iletimini olumsuz etkileyecek şekilde tasarlandığı gözlemlenmiştir. Yapıların bir kısmında dolgu duvarları kirişlere oturtmak amacıyla tali kirişler tasarlanmış ancak bu uygulama saplama kiriş oluşumunu ve dolayısıyla kirişlere gelen kesme kuvvetini artırmıştır. Aynı zamanda tasarımdan kaynaklanan hasarlara düzensizlikler de eklenmiştir. Şekil 5.20’de depremde ağır hasar almış yapıların planlarında düzensizlik bulunmasına veya bulunmamasına göre dağılımları grafik şeklinde gösterilmiştir.



Şekil 5.20. Elazığ (Sivrice) depreminde ağır hasar almış yapıların plan durumu (FYHAG, 2020)


Şekil 5.21’de çeşitli düzensizlikler nedeniyle ağır hasar alan yapıların sayısı grafik şeklinde gösterilmiştir.



Şekil 5.21. Elazığ (Sivrice) depreminde ağır hasar alan yapıların düzensizlik çeşitlerine göre sayılarının dağılımı (FYHAG, 2020)

Araştırmacı grup tarafından incelenen ağır hasarlı binalardan %62’sinin bitişik nizama sahip olduğunu ve bu binaların %43’ünün ise döşemelerinin arasında kot farkının

olduğu gözlemlenmiştir (FYHAG, 2020). Bu durum çekiçleme etkisinin görülmesine neden olmuştur. Şekil 5.22’de verilen grafikler bitişik ve ayrık nizamlı yapıların yüzdelerini, bitişik nizamla sahip yapıların döşeme seviyelerinin aynı veya farklı olmasına göre yüzdelerini göstermektedir.



(a) **Şekil 5.22.** Elazığ (Sivrice) depreminde ağır hasar alan yapıların bina inşaat nizamları yüzdeleri (a), Elazığ (Sivrice) depreminde ağır hasar alan bitişik nizamla sahip yapıların döşeme seviyelerine göre yüzdeleri (b) (FYHAG, 2020)

Şekil 5.23’te Elazığ’da farklı döşeme kotlarına sahip bitişik nizamlı iki yapı gösterilmiştir. Kat sayısı diğerine göre daha fazla olan binanın kolonlarında çekiçleme etkisinden dolayı hasarlar gözlemlenmiştir.



Şekil 5.23. Çekiçleme hasarı (Sayın ve ark, 2021)

Şekil 5.24'te ise derz boşluğu bırakılmadan inşa edilmiş bir yapıda deprem sonrasında oluşan derz çatlağının görüntüsü verilmiştir.



Şekil 5.24. Yeterli derz bırakılmamış bir yapıda görülen hasar

Çalışmada yapımdan kaynaklanan hasarların oluşumunda birçok iş kaleminin etkisi olduğuna yer verilmiştir. Malzeme özelliklerini incelemek amacıyla alınan numuneler beton dayanımının olması gerekenin çok çok altında olduğunu göstermiştir. Sahada yapılan gözlemler, kolon-kiriş boyutlarının minimum değerleri sağladığını ancak birleşim bölgelerinde yeterli donatı sıklaştırmasının yapılmadığını ortaya koymuştur (FYHAG, 2020).

Bikçe ve Erdem (2020) çalışmalarında, Elazığ (Sivrice) depremi sırasında yıkılan 4 binadan 35 beton ve 12 donatı örneği toplamışlardır. Ayrıca depremin hemen ardından acil yıkılacak olan ağır hasarlı binalardan da 69 beton ve 70 donatı örneği almışlardır. İncelemeler sırasında çok sayıda korozyona uğramış donatı, yuvarlak nehir/göl agregaları ve organik maddeler içeren betona rastlanmıştır. Öte yandan, donatıların detaylandırılmasında kritik eksiklikler gözlemlenmiştir. Özellikle etriye aralığı ve bindirme eklerinin uzunluğu ile ilgili kusurlarla sıklıkla karşılaşmıştır. Şekil 5.25'te etriye aralıklarının uygun seçilmediği ve nervürsüz donatı kullanılan bir kolonun deprem sonrası aldığı hasar gösterilmiştir.



Şekil 5.25. Uygun olmayan etriye aralığından ve nervürsüz donatı kullanımından dolayı oluşan kolon hasarı

Elazığ (Sivrice) depreminden hemen sonra yapılan bir çalışmada ise gözlemlenen hasarlar; kısa kolon, güçlü kiriş–zayıf kolon, korozyon, kalkan duvarların göçmeleri, dolgu duvar hasarlarıdır (Sayın ve ark, 2021). Şekil 5.26’da kısa kolon hasarı oluşmuş bir yapı görüntüsüne yer verilmiştir.



Şekil 5.26. Kısa kolon hasarı (Sayın ve ark, 2019)

Bunun yanında çeşitli elektrik/su hatları ve aksesuarlarının yapı elemanlarına zarar vererek döşenmesi, yanlış beton yerleştirilmesi gibi örneklere de rastlanmıştır. Hasarların büyük çoğunluğunun malzeme ve işçilik kusurlarından kaynaklandığı saptanmıştır. Elazığ (Sivrice) depreminden sonra yıkılan binalardan alınan beton ve betonarme numuneler üzerinde yapılan deneyler sonucunda, binaların malzeme özelliklerinin ilgili standart ve yönetmeliklerde belirtilen şartları sağlamadığı ortaya çıkmıştır. Çoğu yapının inşa edildiği yıllarda hazır beton tesislerinin ülkemizde yaygın olmaması bu sorunun en önemli nedenlerinden biridir (Bikçe ve Erdem, 2021). Tesisat borularının kolon ve kirişlerin içerisinden geçirilmesi, saplama kiriş uygulaması, beton dökümünde yeterince dikkat edilmediği durumlarda oluşan segregasyon gibi nedenlerden dolayı betonarme elemanlar hasar almıştır. Şekil 5.27’de malzeme, işçilik ve kullanım hataları gösterilmiştir.



Şekil 5.27. Malzeme, işçilik ve kullanım kusurları

Hasarlı binalarda beton basınç dayanımını belirlemek amacıyla yapılan Schmidt çekiç testi sonucunda dayanım genel olarak 8-12 MPa arasında ölçülmüştür. Bikçe ve

Erdem tarafından yapılan çalışmada yıkılan binalar için en yüksek beton basınç dayanımı değeri 14,43 MPa, en düşük değeri ise 4,48 MPa olarak ölçülmüştür. Genel olarak ortalama beton dayanımı 9,58 MPa olarak hesaplanmıştır ve bu değer oldukça düşüktür (Bikçe ve Erdem, 2019).Yapıların büyük bir bölümünde de sıva veya duvarlarda yapısal olmayan eleman hasarları meydana gelmiştir. Bu durum binaların yatay rijitliğe sahip olduğunu göstermektedir (Doğan ve ark, 2020).

Elazığ (Sivrice) depreminin ardından kolonlarda görülen hasarlardan birkaç örnek Şekil 5.28’de verilmiştir.





Şekil 5.28. Kolonlarda görülen hasarlar

Elazığ (Sivrice) depreminde kirişlerde oluşan hasar örnekleri Şekil 5.29’da verilmiştir.





Şekil 5.29. Kirişlerde oluşan hasarlar

Şekil 5.30’da Elazığ (Sivrice) depreminin ardından perdelerde görülen hasarlar verilmiştir.





Şekil 5.30. Perde duvarlarda görülen hasarlar

Şekil 5.31’de Elazığ (Sivrice) depremi sırasında oluşan sıva çatlakları örnekleri verilmiştir.



(a)



(b)

Şekil 5.31. Dolgu duvar ile taşıyıcı sistem çerçevesi arasında oluşan sıva çatlağı (a); tesisat boşluğu dolayısıyla oluşan sıva çatlağı (b)

Şekil 5.32’de dolgu duvarlarda depremten sonra oluşan çatlaklara örnek verilmiştir.






Şekil 5.32. Dolgu duvarlarda oluşan hasarlar

5.1.3. İzmir (Seferihisar) Depremi


30 Ekim 2020 tarihinde saat 14.51’de Ege Denizi’nde bulunan Sisam Adası’nın kuzeyi ve İzmir açıkları arasında kalan bölgede meydana gelen $M_w = 6,6$ büyüklüğündeki depremin süresi AFAD raporuna göre 15,68 sn olarak ölçülmüştür. Depremin odak derinliği AFAD tarafından 14,9 km, Kandilli Rasathanesi tarafından 12 km olarak belirlenmiştir. Bu derinlik değerleri söz konusu depremin sığ depremler kategorisine girdiğini göstermektedir. Başta İzmir olmak üzere Ege Bölgesinde ve Marmara Bölgesinde hissedilmiştir. Şekil 5.33’te depremin meydana geldiği bölgenin deprem risk haritasına yer verilmiştir.

1. dereceden deprem bölgesi olan İzmir’de 30 Ekim 2020’de meydana gelen depremin şiddeti AFAD tarafından VIII olarak, Kandilli Rasathanesi tarafından VII olarak ölçülmüştür. Şekil 5.35’te tahmini şiddet haritaları verilmiştir.




Şekil 5.35. AFAD raporuna göre tahmini şiddet haritası (a), Kandilli Rasathanesi raporuna göre tahmini şiddet haritası (b) (AFAD, 2020; KRDAE, 2020)

Depremin ardından AFAD raporuna göre 31 Aralık 2020 tarihine kadar büyüklükleri $0,7 \leq M_w \leq 5,1$ arasında olan 5799, Kandilli Rasathanesi raporuna göre 30 Kasım 2020 tarihine kadar büyüklükleri $0,8 \leq M_w \leq 5,2$ arasında değişen toplam 5068 adet artçı şok meydana gelmiştir. Şekil 5.36’da depremin ardından meydana gelen artçı şokların haritalarına yer verilmiştir.




Şekil 5.36. AFAD raporuna göre artçı şok haritası (a), Kandilli Rasathanesi’nin raporuna göre artçı şok haritası (b) (AFAD, 2020; KRDAE, 2020)

Söz konusu artçı deprem sayılarının büyüklüklerine göre dağılımı Şekil 5.37’de grafik şeklinde gösterilmiştir. Artçı depremlerin günlere göre dağılımı ise Şekil 5.38’de grafik şeklinde verilmiştir.



Şekil 5.37. İzmir (Seferihisar) depreminden sonra meydana gelen artçı şokların büyüklükleri ve sayıları (KRDAE, 2020)



Şekil 5.38. İzmir (Seferihisar) depreminin ardından meydana gelen artçı şok sayısının günlere göre dağılımı (KRDAE, 2020)

Deprem, Sisam adasının kuzeyinde bulunan doğu-batı yönlü uzanan bir fay üzerinde gerçekleşmiştir. Depremi merkez üssüne en yakın istasyonlarda ölçülen değerler Çizelge 5.3'te verilmiştir.


Çizelge 5.3. İzmir ve Aydın illerinde bulunan ivmeölçerlerin kaydettiği bilgiler (AFAD, 2020)

İstasyon Kodu	İl	R _{epi} (km)	PGA (gal)
3536	İzmir	34,75	50,22
0905	Aydın	42,95	179,3
3523	İzmir	48,94	80,32
3533	İzmir	51,38	73,64
3516	İzmir	54,57	47,29
3538	İzmir	56,67	85,48
3528	İzmir	58,23	117,57
3519	İzmir	69,23	150,09
3513	İzmir	72,0	106,28
3526	İzmir	78,75	88,77

İvme ölçerlerden alınan bilgiler ışığında en yüksek ivme değerinin 179,3 gal değeri ile 0905 koduna sahip istasyonda ölçüldüğü söylenebilir.

Meydana gelen depremde 116 kişi hayatını kaybetmiştir. Depremi ardından küçük çapta da olsa İzmir'in Seferihisar ilçesinde bulunan Sığacık mahallesinde tsunami meydana gelmiştir. Tekneleri denizden alıp karaya doğru sürükleyen tsunami onlarca metre karayı sular altında bırakmış, ağaçları yerinden oynatmıştır (Utkucu ve ark, 2020). Aynı zamanda depremden 10 dakika sonra Samos Adası'nın Vathy Körfezi'nde yükseklikleri 2 m'ye ulaşan tsunami dalgaları görülmüştür. Bu dalgalar karadan 100 m içeriye kadar girmiş, çeşitli hasarlara neden olmuş ancak herhangi bir can kaybı yaşanmamıştır (Eyidoğan, 2020).

Deprem sonrası Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından yayınlanan rapora göre 54 yıkık bina, 36 acil yıkılması gereken bina, 602 ağır hasarlı bina, 720 orta hasarlı bina, 6848 az hasarlı bina tespit edilmiştir (ÇŞB, 2020). Şekil 5.39'da binaların hasar seviyeleri dağılımı grafik şeklinde gösterilmiştir.



Şekil 5.39. İzmir (Seferihisar) depreminde binaların aldıkları hasar derecelerine göre dağılımı (ÇŞB, 2020)

Şekil 5.40'ta İzmir (Seferihisar) depremi sırasında çöken yapıların görüntüleri verilmiştir.






Şekil 5.40. Yıkılan yapıların görüntüleri

30 Ekim 2020 tarihinde gerçekleşen İzmir (Seferihisar) depreminde can ve mal kayıpları yoğunluklu olarak Bayraklı ve Bornova çevresinde meydana gelmiştir. Özellikle 7-10 katlı betonarme yapılar deprem sırasında ciddi hasarlar almıştır. Bu durumun en önemli nedeni zeminin büyütme etkisidir. İzmir Bayraklı, suya doygun ve gevşek bir toprağa sahip olduğundan 6,6 büyüklüğündeki bir deprem, beklenenden daha çok hasara neden olmuştur (Çınar ve ark, 2021). Şekil 5.41’de İzmir bölgesinde bulunan betonarme binalar, hasar alma durumlarına göre renklendirilmiş şekilde haritada gösterilmiştir.




Şekil 5.41. İzmir (Seferihisar) depreminde, betonarme binaların hasar alma derecelerine göre sınıflandırılıp haritada gösterimi (ÇŞB, 2021)

Şekil 5.42’de İzmir (Seferihisar) depreminin ardından yıkılan, acil yıkılacak olan ve ağır hasar alan betonarme yapıların ilçelere göre dağılımı grafik şeklinde verilmiştir.




Şekil 5.42. İzmir (Seferihisar) depreminde yıkılan, acil yıkılması gereken ve ağır hasar alan betonarme yapıların ilçelere göre dağılımı (Demir ve ark, 2020)

Elazığ’da olduğu gibi İzmir’de bulunan yapıların da bir kısmı eski olduğundan kurlsız yapılmış, dönemin yönetmeliğine uygun yapılsa bile yönetmelik yetersizliğinden kaynaklanan sorunlar deprem dolayısıyla gün yüzüne çıkmıştır. Şekil 5.43’te verilen grafikte yapıların kat sayısına ve inşa edildiği yıllara göre dağılımı verilmiştir.




Şekil 5.43. İzmir’de bulunan betonarme yapıların kat sayılarına ve inşa yıllarına göre ayrımı (Yakut ve ark, 2021)

Grafikten de görüleceği gibi 1998 ve 2000 yılları arasında inşa edilen betonarme yapılar İzmir’de bulunan tüm betonarme yapıların yaklaşık %50’sini, 2000 yılı öncesi inşa edilen betonarme yapıların ise toplam betonarme yapıların %17’sini oluşturmaktadır. 2000’li yıllardan sonra yapılan yapıların yapı denetim uygulamasına tabi olduğu, daha sık denetlendiği ve yönetmelik kurallarının daha katı bir şekilde uygulandığı göz önüne alındığında İzmir’de bulunan betonarme yapıların yaklaşık %67’sine tekabül eden ciddi bir kısmı deprem yüklerine dayanıklı şekilde inşa edilmemiştir. AFAD raporuna göre toptan çökme yaşanmış binaların genel olarak 1990-1994 yılları arasında inşa edildiği ve bu binalarda uygulama ve detaylandırma eksikliği bulunduğu gözlemlenmiştir. Şekil 5.44’te yapıların inşa edildikleri yıllara göre ve aldıkları hasara göre sınıflandırılması grafik şeklinde verilmiştir.




Şekil 5.44. İzmir (Seferihisar) depreminde yapıların inşa edildikleri yıllara göre az, orta ve ağır hasarlı olarak sınıflandırılması (Yakut ve ark, 2021)

İzmir (Seferihisar) depreminin ardından yapılan çalışmalarda bir başka sınıflandırma betonarme yapıların kat sayıları ve hasar derecelerine göre yapılmıştır. Şekil 5.45’te söz konusu sınıflandırma grafik şeklinde gösterilmiştir.



Şekil 5.45. İzmir (Seferihisar) depreminde az, orta ve ağır hasar alan yapıların kat sayılarına göre sınıflandırılması (Yakut ve ark, 2021)

Depremde en çok hasar 1-3 katlı yapılarda meydana gelmiştir. Ağır hasar alan, yıkılan ve yıkılması gereken betonarme binalar daha ayrıntılı incelendiğinde kat sayılarına göre dağılımı Şekil 5.46’da verilmiştir.



Şekil 5.46. İzmir (Seferihisar) depreminde yıkılan, acil yıkılması gereken ve ağır hasar alan betonarme yapıların kat sayılarına göre dağılımı (Demir ve ark, 2020)

Yukarıda verilen grafikten de görülebileceği gibi betonarme binalar özelinde en fazla hasar 8 ve 9 katlı yapılarda gözlemlenmiştir.

Kalitesiz beton kullanımı ve yetersiz donatılandırma binaların ağır hasar almasına neden olmuştur. Ayrıca deprem titreşimleri nedeniyle kabuk betonda dökülmeler gözlemlenen yerlerde hasarın korozyon hasarı olduğu, depremin korozyon hasarının gün yüzüne çıkardığı gözlemlenmiştir. Betonarme binalarda dıştan yapılan gözlemlerde ciddi hasarlar görülmezken, içeriden yapılan hasar tespit çalışmalarında taşıyıcı elemanlarda önemli hasarlar görüldüğü raporlanmıştır (AFAD, 2021). Hasarların çoğu, TBDY-2018’de bahsedilen düzensizlik durumlarından kaynaklanmıştır. Bunlara zayıf ve yumuşak katlar, ağır çıkmalar, kısa kolonlar örnek gösterilebilir.

Şekil 5.47’de yumuşak kat düzensizliği nedeniyle İzmir (Seferihisar) depreminden sonra hasar almış bir yapının görüntüsü verilmiştir.



Şekil 5.47. Yumuşak kat düzensizliği nedeniyle çökmüş bir bina (AFAD, 2021)

Şekil 5.48’de ağır çıkmalar bulunması nedeniyle İzmir (Seferihisar) depreminde hasar almış bir yapının görüntüsü verilmiştir.



Şekil 5.48. Ağır çökmelerinin bulunması nedeniyle kısmi göçme yaşanmış bir bina (AFAD, 2021)

Şekil 5.49’da kısa kolon düzensizliği nedeniyle hasar almış bir yapısal eleman görüntüsü verilmiştir.



Şekil 5.49. Kısa kolon oluşumu nedeniyle hasar alan bir yapısal eleman

Bitişik nizam şeklinde inşa edilmiş betonarme yapılarda yeterli derz boşluğu bırakılmadığından olası bir depremde yapıların kendi derz boşluklarını kendilerinin açtığına veya çekiçleme etkisi dolayısıyla her iki yapının da hasar almasına neden

olduđuna daha nce alıřma kapsamında deđinilmiřtir. řekil 5.50’de depremin ardından yetersiz derz bořluđu nedeniyle hasar almıř bir yapı grnts verilmiřtir.



řekil 5.50. Derz bořluđu bırakılmaması nedeniyle hasar alan bir yapı

Depremde ciddi hasar almıř yapısal elemanlar zerinde yapılan incelemelerde kesme kuvvetlerini karřılayan ve donatıların burkulmasını engelleyen etriyelerin yeterli sayıda ve aralıkta kullanılmaması, kullanılan etriyelerin de ynetmelikte bulunan 135°’lik kanca kuralına uygun olmadıđı gzlemlenmiřtir. řekil 5.51’de yetersiz etriye nedeniyle hasar alan bir yapı elemanı grnts verilmiřtir.



Şekil 5.51. Uygun etriye kullanılmaması dolayısıyla hasar almış bir kolon

Depremden sonra bilirkişiler hasar tespit çalışması sırasında pek çok betonarme yapıda tasarım ve kullanımdan kaynaklı kusurlar gözlemlemişlerdir. Şekil 5.52’de bu tür kusurların görselleri verilmiştir.





Şekil 5.52. Tasarım ve kullanım kusurları

Depremi ardından yapılan hasar tespit çalışmalarında saptanan kolon hasarlarından birkaç örnek Şekil 5.53'te verilmiştir.





Şekil 5.53. Hasar alan kolonlar

Şekil 5.54’te hasar görülen perde duvarların görüntüsüne yer verilmiştir.





Şekil 5.54. Hasar alan perde duvarlar

Şekil 5.55'te kirişlerde görülen hasarlara örnek gösterilmiştir.





Şekil 5.55. Hasar alan kirişler

Deprem sırasında yapısal olmayan elemanlarda da hasarlar oluşmuştur. Şekil 5.56'da sıva çatlaklarına örnek verilmiştir.



(a)




(b)

Şekil 5.56. Dolgu duvar ile taşıyıcı sistem arasında oluşan sıva çatlakları(a), tesisat boşlukları nedeniyle oluşan sıva çatlakları (b)

Şekil 5.57’de deprem sırasında dolgu duvarlarda oluşan hasarlar gösterilmiştir.







Şekil 5.57. Dolgu duvar hasarları


Çalışma kapsamında anlatılan ülkemizde meydana gelen üç güncel deprem ile ilgili bilgiler Çizelge 5.4'te karşılaştırmalı şekilde verilmiştir.

Çizelge 5.4. Ülkemizde meydana gelen güncel depremlerin bilgileri

	İstanbul (Silivri)	Elazığ (Sivrice)	İzmir (Seferihisar)
M_w	5,8	6,8	6,6
PGA (KG)	84,93 cm/s ²	292,8 cm/s ²	179,3 cm/s ²
PGA (DB)	81,62 cm/s ²	235,8 cm/s ²	149,31 cm/s ²

**Türkiye
Deprem
Tehlike
Haritası'nı
a göre
bölgenin
deprem
tehlikesi**





5.2. Verilerin İstatistikleri

Çalışma kapsamında Derin Öğrenme Ağı olan ESA’da görüntü sınıflandırma işlemi yapılırken kullanılan veriler İstanbul (Silivri), İzmir (Seferihisar) ve Elazığ (Sivrice) depremleri sonrasında saha çalışmalarından elde edilen betonarme yapı hasar görüntüleridir. Depremler sonrası saha çalışmalarından betonarme yapılarda meydana gelen kolon, kiriş ve perde elemanlar gibi yapısal taşıyıcı elemanlar ile dolgu duvar gibi yapısal olmayan elemanlarda oluşan hasar mekanizmaları incelenmiş ve bu elemanlardan hasar görüntüleri toparlanmıştır. Görüntüler Çevre, Şehircilik ve İklim Değişikliği Bakanlığı’nın “hasartespit.csb.gov.tr” sitesinden ve tez danışmanı Sayın Dr.Öğr.Üyesi Gamze Doğan ve arkadaşları (Doğan vd., 2020) tarafından yapılan saha çalışmalarından elde edilmiştir.

Çalışma kapsamında toplanan verilerden örnekler Şekil 5.58, 5.59, 5.60 ve 5.61’de gösterilmiştir.




Şekil 5.58. Veri setinde kullanılan kiriş hasarı görüntüleri örnekleri



Şekil 5.59. Veri setinde kullanılan kolon hasarı görüntüleri örnekleri



Şekil 5.60. Veri setinde kullanılan perde hasarı görüntüleri örnekleri






Şekil 5.61. Veri setinde kullanılan yapısal olmayan hasar görüntüleri örnekleri


5.2.1. Veri artırma işleminin uygulanması

Depremler sonrası ilgili lokasyonlarda yapılan saha çalışmalarından betonarme yapılarda yapısal ve yapısal olmayan elemanlara ait toplam 5.966 adet hasar görüntüsü toplanmıştır. Çalışmada özellikle yapısal eleman hasar görüntüleri veri artırma yöntemi ile çoğaltılmıştır. Veri artırma işlemi algoritma yardımıyla değil manuel olarak yapılmıştır. Buradaki amaç, 45° 'lik açı ile oluşan kesme çatlaklarının niteliklerini kaybetmemesini sağlamaktır. Bu nedenle sadece aynalama ve 180° döndürme uygulamaları ile yapılan veri artırma işlemi sonucunda elde edilen görüntü sayısı 9.680 olmuştur. Şekil 5.62'de veri artırma işlemi gösterilmiştir. Algoritma için tüm hasar görüntülerini içeren 9.680 adet fotoğrafın olduğu bir veri havuzu oluşturulmuştur.



(a)


(b)



(c) (d)
Şekil 5.62. Orijinal görüntü (a), aynalama yapılmış görüntü (b), 180° döndürülmüş görüntü (c), 180° döndürülmüş görüntünün aynalama yapılmış görüntüsü (d)


5.2.2. Verilerin dağılımı

Çalışma kapsamında elde edilen toplam 9.680 adet hasar görüntüsünden 118 tanesi İstanbul (Silivri) depreminin ardından, 3.900 tanesi Elazığ (Sivrice) depreminin ardından ve 5.662 tanesi ise İzmir (Seferihisar) depreminin ardından çekilen hasar görüntülerinden elde edilmiştir. Şekil 5.63'te verilerin depremlere göre dağılımı grafik şeklinde gösterilmiştir.




Şekil 5.63. Verilerin depremlere göre dağılımı


İstanbul (Silivri) depremi sonrası çekilen 118 hasar görüntüsünün 80'i yapısal eleman hasarı, kalan 28'i ise yapısal olmayan eleman hasarıdır. Elazığ (Sivrice) depremi sonrası çekilen 3.900 hasar görüntüsünden 2.340'sı yapısal eleman hasarı, 1.560'ı ise yapısal olmayan eleman hasarıdır. İzmir (Seferihisar) depremi sonrası çekilen 5.662 adet hasar görüntüsünden ise 2.539 tanesi yapısal eleman hasarı ve kalan 3.113 tanesi yapısal olmayan eleman hasarıdır. Şekil 5.64'te verile grafikler anlatılan bu dağılımları göstermektedir.



(a)




(b)




(c)
Şekil 5.64. İstanbul (Silivri) depreminden (a), Elazığ (Sivrice) depreminden (b), İzmir (Seferihisar) depreminden (c) elde edilen hasar görüntülerinin dağılımı

Tüm depremler sonrası elde edilen toplam elde edilen 9.680 verinin 4.959 tanesi yapısal eleman hasarı görüntülerinden, kalan 4.721 tanesi ise yapısal olmayan eleman hasarı görüntülerinden oluşmaktadır. Şekil 5.65'te verilerin yapısal ve yapısal olmayan eleman hasarı olmasına göre dağılımı grafik şeklinde gösterilmiştir.



Şekil 5.65. Çalışma kapsamında elde edilen verilerin yapısal ve yapısal olmayan eleman hasarı olmalarına göre dağılımı

Veri toplama çalışmasında elde edilen 4.959 betonarme yapısal eleman hasarı görüntüsünden 1.804 tanesi kolon, 3.010 tanesi kiriş, kalan 145 tanesi ise perde elemanların hasar görüntüleridir. Şekil 5.66'da yapısal eleman hasarlarının dağılımı grafik şeklinde gösterilmiştir.



Şekil 5.66. Yapısal eleman hasarlarının elemanlara göre dağılımı

5.3. Derin Öğrenme Algoritmasının Geliştirilmesi

Bu tez çalışmasının amacı, betonarme binalarda meydana gelen deprem hasarlarını yapısal elemanda oluşan hasar veya yapısal olmayan elemanda oluşan hasar mekanizması şeklinde iki sınıfa ayırmaktır. Algoritmanın bu işlemi gerçekleştirirken çatlak görünümü, beton dökülmesi, donatı açığa çıkması, donatı burkulması, sıva çatlağı, tuğla duvar çatlağı gibi ayrıntıları öğrenip, bu noktalara odaklanıp buna göre sınıflandırma yapması amaçlanmıştır. Derin sinir ağları veriler üzerinden öğrenip ardından farklı veriler üzerinden tahmin yapabilen algoritmalarlardır. Bu nedenle elde edilen veriler algoritmayı eğitmek ve test etmek üzere eğitim ve test seti olarak iki farklı gruba ayrılmalıdır. Çalışmada verilerin %85'i eğitim, %15'i ise test verisi olarak ayrılmıştır. Yapısal elemanlar kolon, kiriş ve perde olmak üzere üç grupta incelendiğinden dolayı sistemin en iyi şekilde öğrenmesini sağlamak amacıyla rastgele veri ayrımı yapılmamıştır. Burada anlatılmak istenen 1.804 kolon hasarı görüntüsünden 1.533 tanesi

eğitim, 271 tanesi test verisi sınıfına, 3.010 kırış hasarı görüntüsünden 2.559 tanesi eğitim, 451 tanesi test verisi sınıfına, 145 perde hasarı görüntüsünden ise 123 tanesi eğitim ve 22 tanesi test verisi sınıfına atanmıştır. Toplam 4.721 yapısal olmayan eleman hasarından 4.013 tanesi eğitim, 708 tanesi test verisi olarak ayrılmıştır. Özet olarak 9.680 görüntüden %85'ine tekabül eden 8.228 tanesi modeli eğitmek için, kalan 1.452 tanesi modeli test etmek amacıyla kullanılmıştır.

Bu çalışmada, betonarme binaların deprem sırasında aldıkları hasarları yapısal ve yapısal olmayan eleman hasarı şeklinde sınıflandırılmasını sağlayan bir algoritma oluşturulmuştur. Bu amaç kapsamında son yıllarda sıklıkla tercih edilen, açık kaynak kodlu programlama dillerinden Python yazılım programı kullanılmıştır. Geliştirilmesi amaçlanan model bir görüntü sınıflandırıcı olduğundan DÖ'nün mimarilerinden biri olan ESA tercih edilmiştir. Python programında bulunan çeşitli kütüphaneler içerisinde yine DÖ uygulamaları için tercih edilen Keras ve TensorFlow kütüphanesinden çalışmada yararlanılmıştır. Algoritmanın geliştirilmesinde Intel® Tiger Lake Core™ 17-11800H 8C/16T; 2.3 GHz > 4.6 GHz işletim sistemine ve nVIDIA® GeForce® RTX3060 Max-Performance 6GB GDDR6 192-Bit DX12 ekran kartına sahip bilgisayar kullanılmıştır. DÖ modelleri veri sayısına bağlı olarak performans göstermektedir. Burada bahsedilen veri sayısı arttıkça modellerin başarısı da doğru orantılı şekilde artmaktadır. Elde edilen veri sayıları bir modeli baştan eğitmek için yeterli olmadığından çalışmada çeşitli Transfer Öğrenme yöntemleri kullanılmaktadır. Bu çalışmada daha önce benzer çalışmada kullanılmış ve oldukça başarılı sonuçlar elde edilmiş olan VGGNet modellerinden VGG 19 modeli tercih edilmiştir. Veri sayısına bağlı olarak model başarısının arttığı göz önünde tutularak mevcut veriler üzerinden veri artırma işlemi gerçekleştirilmiştir. Yapısal elemanlarda deprem sırasında meydana gelen özellikle kesme gibi belirli açılarda oluşan çatlakların özelliklerini kaybetmemesi için veri artırma işleminde görüntüler sadece 180° döndürülmüş ve aynalama işlemi yapılmıştır. Algoritmada oluşabilecek yanlış odaklanmaların önüne geçmek amacıyla gereksiz detaylar elimine edilmiştir. Hasar görüntülerinin büyük bir kısmı evlerin veya işyerlerinin içinden çekildiğinden dolayı görüntüde bulunan duvar kağıdı, tablo, çiçek gibi nesneler kırılarak modelin sadece hasarın şekline ve derinliğine odaklanması sağlanmıştır. VGG 19 modelinin geliştirilmesi aşamasında kullanılan veri boyutları 224x224x3 olduğundan yeni oluşturulacak model ile benzeşmesi amacıyla hasar görüntüler üzerinde yeniden boyutlandırma işlemi yapılmıştır. 2048x2048x3 matris değerlerine sahip görüntüler 224x224x3 boyutlarına indirilmiştir.


Veri üzerinde yapılan tüm bu ön işlemlerin ardından kullanılacak olan Keras ve TensorFlow kütüphaneleri algoritmaya yüklenmiş, transfer öğrenme modellerinden seçilen VGG 19 modeli tanımlanmıştır. Transfer öğrenme modeli olan VGG 19, bir ardışık (sequential) modeldir. Ardışık model, sıralı katmanlardan oluşan bir sinir ağını temsil etmektedir, bu sayede kolay şekilde model oluşumu sağlanmaktadır. Çizelge 5.5'te algoritmada kullanılmak üzere yüklenen VGG 19 mimarisinin katmanlarına, filtre boyutlarına ve çıkış tiplerine yer verilmiştir.

Çizelge 5.5. VGG 19 mimarisinin katmanları

	Katman tipleri	Çıkış şekli	Parametreler
	Giriş katmanı	(224, 224, 3)	0
1.Blok	1. Evrişim katmanı	(224, 224, 64)	1792
	2. Evrişim katmanı	(224, 224, 64)	36928
	Maksimum havuzlama katmanı	(112, 112, 64)	0
2.Blok	1. Evrişim katmanı	(112, 112, 128)	73856
	2. Evrişim katmanı	(112, 112, 128)	147584
	Maksimum havuzlama katmanı	(56, 56, 128)	0
3.Blok	1. Evrişim katmanı	(56, 56, 256)	295168
	2. Evrişim katmanı	(56, 56, 256)	590080
	3. Evrişim katmanı	(56, 56, 256)	590080
	4. Evrişim katmanı	(56, 56, 256)	590080
	Maksimum havuzlama katmanı	(28, 28, 256)	0
4.Blok	1. Evrişim katmanı	(28, 28, 512)	1180160
	2. Evrişim katmanı	(28, 28, 512)	2359808
	3. Evrişim katmanı	(28, 28, 512)	2359808
	4. Evrişim katmanı	(28, 28, 512)	2359808
	Maksimum havuzlama katmanı	(14, 14, 512)	0
5.Blok	1. Evrişim katmanı	(14, 14, 512)	2359808
	2. Evrişim katmanı	(14, 14, 512)	2359808
	3. Evrişim katmanı	(14, 14, 512)	2359808
	4. Evrişim katmanı	(14, 14, 512)	2359808

Maksimum havuzlama katmanı	(7, 7, 512)	0
Düzleştirme katmanı	(25088)	0
1.Tam bağlantılı katman	(4096)	102764544
2.Tam bağlantılı katman	(4096)	16781312
Sınıflandırma katmanı	(1000)	4097000

Eğitim ve test verileri sisteme verildikten sonra tanımlanan VGG 19 modelinin sadece son katmanı olan sınıflandırma katmanı kaldırılmıştır. Bu işlem, söz konusu modelin 1000 sınıflı bir işlem için eğitilmiş olmasından kaynaklanmaktadır. Çalışma kapsamında yapılan işlem iki sınıflı (yapısal ve yapısal olmayan hasarlar) bir problem üzerinedir. Bu nedenle ikili sınıflandırma yapacak yeni bir katman eklenmiştir. Şekil 5.67’de algoritmanın geliştirilmesi aşamasında son katmanı değiştirilen VGG 19 mimarisine yer verilmiştir.



Şekil 5.67. Sınıflandırma katmanı değiştirilmiş VGG 19 mimarisi

Çizelge 5.6’da ise 1000 sınıflı işlem yerine 2 sınıflı işlem için revize edilen VGG 19 katmanlarının listesi verilmiştir.

Çizelge 5.6. İkili sınıflandırma modeli için uyarlanmış VGG 19 modeli

	Katman tipleri	Çıkış şekli	Parametreler
	Giriş katmanı	(224, 224, 3)	0
1.Blok	1. Evrişim katmanı	(224, 224, 64)	1792
	2. Evrişim katmanı	(224, 224, 64)	36928
	Maksimum havuzlama katmanı	(112, 112, 64)	0
2.Blok	1. Evrişim katmanı	(112, 112, 128)	73856
	2. Evrişim katmanı	(112, 112, 128)	147584
	Maksimum havuzlama katmanı	(56, 56, 128)	0
3.Blok	1. Evrişim katmanı	(56, 56, 256)	295168
	2. Evrişim katmanı	(56, 56, 256)	590080
	3. Evrişim katmanı	(56, 56, 256)	590080
	4. Evrişim katmanı	(56, 56, 256)	590080
	Maksimum havuzlama katmanı	(28, 28, 256)	0
4.Blok	1. Evrişim katmanı	(28, 28, 512)	1180160
	2. Evrişim katmanı	(28, 28, 512)	2359808
	3. Evrişim katmanı	(28, 28, 512)	2359808
	4. Evrişim katmanı	(28, 28, 512)	2359808
	Maksimum havuzlama katmanı	(14, 14, 512)	0
5.Blok	1. Evrişim katmanı	(14, 14, 512)	2359808
	2. Evrişim katmanı	(14, 14, 512)	2359808
	3. Evrişim katmanı	(14, 14, 512)	2359808
	4. Evrişim katmanı	(14, 14, 512)	2359808
	Maksimum havuzlama katmanı	(7, 7, 512)	0
	Düzleştirme katmanı	(25088)	0
	1.Tam bağlantılı katman	(4096)	102764544
	2.Tam bağlantılı katman	(4096)	16781312
	Sınıflandırma katmanı	(2)	8194


Modelde kullanılacak olan veri sayısının çok fazla olması hem zaman hem de bilgisayar performansı olarak problem oluşturabilmektedir. Bu nedenle toparlanan veriler belirli sayılarda gruplara ayrılmaktadır. Grup sayısını belirleyen parametre “yığın boyutu (batch size)” parametresi genellikle 2’nin katları olacak şekilde 2,4,6,8,16,32,...512 sayıları arasından seçilebilmektedir. Oluşturulan modelde farklı batch size değerleri arasından en optimum sonucun alınmasını sağlayan 32 değeri seçilmiştir. Eğitimin en iyi şekilde gerçekleşmesi için tüm veriler ağa sadece bir kez değil “döngü (epoch)” parametresi için girilen sayı değeri kadar gösterilmektedir. Bu değer gereğinden küçük seçilmesi başarılı bir model elde edilememesine, gereğinden fazla seçilmesi ise ezberleme durumunun ortaya çıkmasına sebebiyet verebilmektedir. Model oluşturulurken farklı çalışmalarda kullanılan değerler incelenmiş ve epoch değeri 100 olarak belirlenmiştir. Bir ağın parametrelerinin ne kadar hızlı güncellendiğini gösteren öğrenme hızı genellikle 0,1 ile 0,000001 değerleri arasından seçilmektedir. Yapılan çalışmalarda en iyi sonucu almak amacıyla 0,1 değerinden başlatılıp alınan sonuca göre öğrenme hızı küçültülmektedir. Oluşturulan modelde bu bilgiler ışığında öğrenme hızı ilk olarak 0,1 seçilmiştir. Doğrusal verileri doğrusal olmayan verilere dönüştürerek ağın anlayabilmesini sağlayan aktivasyon fonksiyonları evrişimli katmanlarda ve sınıflandırma katmanında kullanılmaktadır. Daha önce yapılmış çalışmalarda kullanılan ve başarılı sonuçlar elde edilen ReLU aktivasyon fonksiyonu evrişimli katmanlarda kullanılmıştır. İki sınıflı sınıflandırma problemlerini başarıyla gerçekleştiren Softmax aktivasyon fonksiyonu ise sınıflandırma katmanında kullanılması için tercih edilmiştir. Algoritmanın yaptığı tahminlerdeki hata oranını belirlemek için “kayıp (loss)” fonksiyonlarından oluşturulan modele en uygun olduğu düşünülen “categorical crossentropy” seçilmiştir. Söz konusu hata oranını minimuma indirmek için her epochta ağı güncelleyen optimizasyon fonksiyonlarından başarısı kanıtlanmış RMSProp tercih edilmiştir. Algoritmanın her bir döngüsü tamamlandığında elde edilen hata ve doğruluk oranlarını görüp bu değerleri yorumlamak amacıyla “metric” parametrelerinden “doğruluk (accuracy)” kullanılmıştır. Çizelge 5.7’de tez çalışmasında oluşturulan ilk modelde seçilen parametre değerleri verilmiştir.

Çizelge 5.7. İlk oluşturulan modelde seçilen parametreler


Transfer öğrenme modeli	VGG 19
Giriş görüntü boyutu	224 x 224 x 3

Yığın boyutu (Batch size)	32
Döngü (Epoch)	100
Optimizasyon fonksiyonu	RMSProp
Metrics	Accuracy
Aktivasyon fonksiyonları	ReLU, Softmax
Kayıp (Loss) fonksiyonu	Categorical Crossentropy
Öğrenme hızı	0,1

Modelin eğitim ve test aşamaları tamamlandıktan sonra elde edilen grafikler Şekil 5.68’de verilmiştir. Şekil 5.68 (a) grafiği her epochta eğitim ve test veri setinden elde edilen kayıp bir başka deyişle hata değerini göstermektedir. Her epochta verilerin tamamı algoritmaya gösterilerek hata değeri kayıp fonksiyonları aracılığıyla hesaplanmakta, geri yayılım algoritmasıyla seçilen optimizasyon fonksiyonu hata oranını minimum değere indirmek için ağı güncellemektedir. İlk epochta elde edilen eğitim kaybı yani maksimum hata %59,71 (0,5971) iken minimum eğitim kaybı ise % 3,53 (0,0353)’tür. Şekil 5.68 (b) grafiği ise her epochta eğitim ve test veri setinden elde edilen başarı değerlerini göstermektedir. İlk epochta elde edilen eğitim başarısı yani minimum eğitim başarısı %78,06 (0,7806) iken maksimum eğitim başarısı %98,81 (0,9881)’dir. Tüm bu değerler göstermiştir ki algoritmanın eğitimi başarılı şekilde gerçekleşmiştir. Ancak doğruluk grafiğinde gösterilen eğitim başarısının giderek artması sabitlememesi maksimum başarının sağlanamadığını epoch sayısının artırılması gerektiğini göstermiştir. Grafiklerdeki doğrulama kaybı ve doğrulama başarısı test setinden elde edilen değerleri ifade etmektedir. Kayıp grafiğindeki doğrulama kaybı maksimum %34,51 (0,3451) iken minimum doğrulama kaybı %13,97 (0,1397) olarak elde edilmiştir. Bunun yanında Şekil 5.68 (a) grafiğindeki doğrulama kaybı grafik çizgisine bakıldığında ufak bir eğimle yaklaşık 35. Epochtan sonra giderek arttığı görülmüştür. Bu artış modelde ezberleme (overfitting) durumunun meydana geldiğini göstermiştir. Doğrulama grafiğindeki doğrulama başarısı minimum %86,25 (0,8625), maksimum doğrulama başarısı ise %95,13 (0,9513) olarak elde edilmiştir. Modelin genel başarı oranı doğrulama grafiğindeki doğrulama başarısının maksimum değeri olarak alınır. Yani ilk modelden elde edilen tahmin başarısı oranı doğruluk metriğine göre %95,13’tür.



(a)



(b)

Şekil 5.68. İlk modelden elde edilen kayıp grafiği (a), İlk modelden elde edilen doğruluk grafiği (b)

Ezberleme durumunu ortadan kaldırmak amacıyla yapılan işlemlerden bir tanesi veri artırmadır. Çalışmada halihazırda veri artırma işlemi yapıldığından dolayı ezberlemenin önüne geçmek için seyreltme (dropout) katmanının eklenmesine karar verilmiştir. Söz konusu katman ardışık VGG 19 modelinde sınıflandırma katmanından hemen önce konumlandırılmaktadır. Yapılan çalışmalarda seyreltme katmanında belirlenen eşik değeri genellikle 0,5'tir. Bu değer altında kalan nöronlar devre dışı

bırakılarak modelin ezberleme durumu engellenmiştir. Son oluşturulan ağ modelinin katmanları Çizelge 5.8’de verilmiştir.

Çizelge 5.8. Son oluşturulan modeldeki VGG 19 katmanları

	Katman tipleri	Çıkış şekli	Parametreler
	Giriş katmanı	(224, 224, 3)	0
1.Blok	1. Evrişim katmanı	(224, 224, 64)	1792
	2. Evrişim katmanı	(224, 224, 64)	36928
	Maksimum havuzlama katmanı	(112, 112, 64)	0
2.Blok	1. Evrişim katmanı	(112, 112, 128)	73856
	2. Evrişim katmanı	(112, 112, 128)	147584
	Maksimum havuzlama katmanı	(56, 56, 128)	0
3.Blok	1. Evrişim katmanı	(56, 56, 256)	295168
	2. Evrişim katmanı	(56, 56, 256)	590080
	3. Evrişim katmanı	(56, 56, 256)	590080
	4. Evrişim katmanı	(56, 56, 256)	590080
	Maksimum havuzlama katmanı	(28, 28, 256)	0
4.Blok	1. Evrişim katmanı	(28, 28, 512)	1180160
	2. Evrişim katmanı	(28, 28, 512)	2359808
	3. Evrişim katmanı	(28, 28, 512)	2359808
	4. Evrişim katmanı	(28, 28, 512)	2359808
	Maksimum havuzlama katmanı	(14, 14, 512)	0
5.Blok	1. Evrişim katmanı	(14, 14, 512)	2359808
	2. Evrişim katmanı	(14, 14, 512)	2359808
	3. Evrişim katmanı	(14, 14, 512)	2359808
	4. Evrişim katmanı	(14, 14, 512)	2359808
	Maksimum havuzlama katmanı	(7, 7, 512)	0
	Düzleştirme katmanı	(25088)	0
	1.Tam bağlantılı katman	(4096)	102764544
	2.Tam bağlantılı katman	(4096)	16781312


Seyreltme katmanı	(4096)	0
Sınıflandırma katmanı	(2)	8194

Kullanılan hiper-parametre değerlerinden modelin başarımını artırmak amacıyla epoch sayısı 150'ye yükseltilmiştir. Bunun yanında öğrenme oranı yine model başarımını artırmak için 0,001 değerine düşürülmüştür. Son modelde kullanılan parametre değerleri Çizelge 5.9'da verilmiştir.


Çizelge 5.9. Son modelde kullanılan parametreler

Parametreler	
Transfer öğrenme modeli	VGG 19
Giriş görüntü boyutu	224 x 224 x 3
Yığın boyutu (Batch size)	32
Döngü (Epoch)	150
Optimizasyon fonksiyonu	RMSProp
Metrics	Accuracy
Aktivasyon fonksiyonları	ReLU, Softmax
Kayıp (Loss) fonksiyonu	Categorical Crossentropy
Seyrelme (Dropout) değeri	0,5
Öğrenme hızı	0,001

Son modelden elde edilen grafikler ise Şekil 5.69'da verilmiştir. Model için toplanan verilerden eğitim seti olarak ayrılan %85'lik kısmından elde edilen minimum eğitim başarısı %80,25 (0,8025) iken maksimum eğitim başarısı ise %95,25 (0,9525)'tir. Bunun yanında kayıp grafiğinde gösterilen eğitim kaybında maksimum değer %56,11 (0,5611), minimum eğitim kaybı değeri ise %13,11 (0,1311)'dir. Bu değerler, modelin başarılı şekilde eğitildiğini göstermektedir. Verilerden test seti olarak ayrılan %15'lik kısmından elde edilen minimum doğrulama başarısı %84,05 (0,8405), maksimum doğrulama başarısı ise %93,13 (0,9313) olarak elde edilmiştir. Ayrıca kayıp grafiğinde bulunan doğrulama kaybında maksimum kayıp değeri %40,66 (0,4066) iken minimum kayıp değeri %21,93 (0,2193)'tür.




(a)



(b)

Şekil 5.69. Son modelden elde edilen kayıp grafiği (a), son modelden elde edilen doğruluk grafiği (b)

Doğruluk grafiğinde en yüksek doğrulama yani test başarıları %93,12 (0,9312) olarak elde edilmiştir. Bu değer, modelin hasar görüntülerini yapısal ve yapısal olmayan eleman hasarı olarak sınıflandırmada %93,12 oranında başarılı olduğunu göstermektedir. Algoritmaya sunulan görüntülerin hangi sınıfa ait olduğu sonucu etiketleme yapılarak çıktı olarak modelden alınmaktadır. Algoritmanın görüntüler üzerinden yaptığı tahminlerle ilgili birkaç örnek görüntü etiketleme Şekil 5.70’de verilmiştir.

Yapısal**Yapısal Olmayan****Yapısal****Yapısal Olmayan****Yapısal****Yapısal Olmayan****Yapısal****Yapısal Olmayan****Yapısal****Yapısal Olmayan****Yapısal****Yapısal Olmayan**

YapisaOlmayan**Yapisa****YapisaOlmayan****Yapisa****YapisaOlmayan****Yapisa****YapisaOlmayan****Yapisa****YapisaOlmayan****Yapisa****YapisaOlmayan****Yapisa**

Yapısal Olmayan



Yapısal



Yapısal Olmayan



Yapısal



Yapısal Olmayan



Yapısal



Yapısal Olmayan



Yapısal



Yapısal Olmayan



Yapısal




Yapısal Olmayan



Yapısal






Şekil 5.70. Modelin başarılı şekilde tahmin edip sınıflandırma yaptığı görüntüler

Model, başarılı tahminlerinin yanı sıra başarısız tahminlerde de bulunmuştur. Başarısız tahminler sonucu yanlış sınıfa ait etiketleme işlemi yapılmıştır.


Şekil 5.71’de söz konusu başarısız tahminlere örnekler verilmiştir.














Şekil 5.71. Modelin başarısız şekilde tahmin edip sınıflandırdığı görüntüler




ESA’da görüntüler üzerinden hasar sınıflandırılması yapılırken algoritmanın görüntünün tam olarak hangi kısmına odaklandığı ve hasar sınıfına da bu odak noktasına göre karar verdiği bilinmektedir. Yüksek doğruluk oranlarına ulaşılsa da yanlış yere odaklanmış ve buna göre sınıflandırma yapmış bir model başarılı olarak nitelendirilemez. Bu nedenle çalışmada ısı haritaları çıkarılmıştır. Söz konusu bu haritalar, odak bölgelerini kırmızı-turuncu renkler ile gösterip algoritmanın görüntüde nerelere odaklanıp tahmin yaptığı hakkında araştırmacılara ipucu vermektedir. Çalışmada çıkarılan ısı haritalarından birkaç örnek Şekil 5.72’de verilmiştir.




Yapısal**Yapısal****Yapısal Olmayan****Yapısal Olmayan****Yapısal****Yapısal**

YapisaOlmayan**YapisaOlmayan****Yapisa****Yapisa****YapisaOlmayan****YapisaOlmayan**


Yapısal**Yapısal****Yapısal Olmayan****Yapısal Olmayan****Yapısal****Yapısal**

Yapısal**Yapısal****Yapısal Olmayan****Yapısal Olmayan****Yapısal****Yapısal**



Şekil 5.72. Modelden elde edilen ısı haritaları

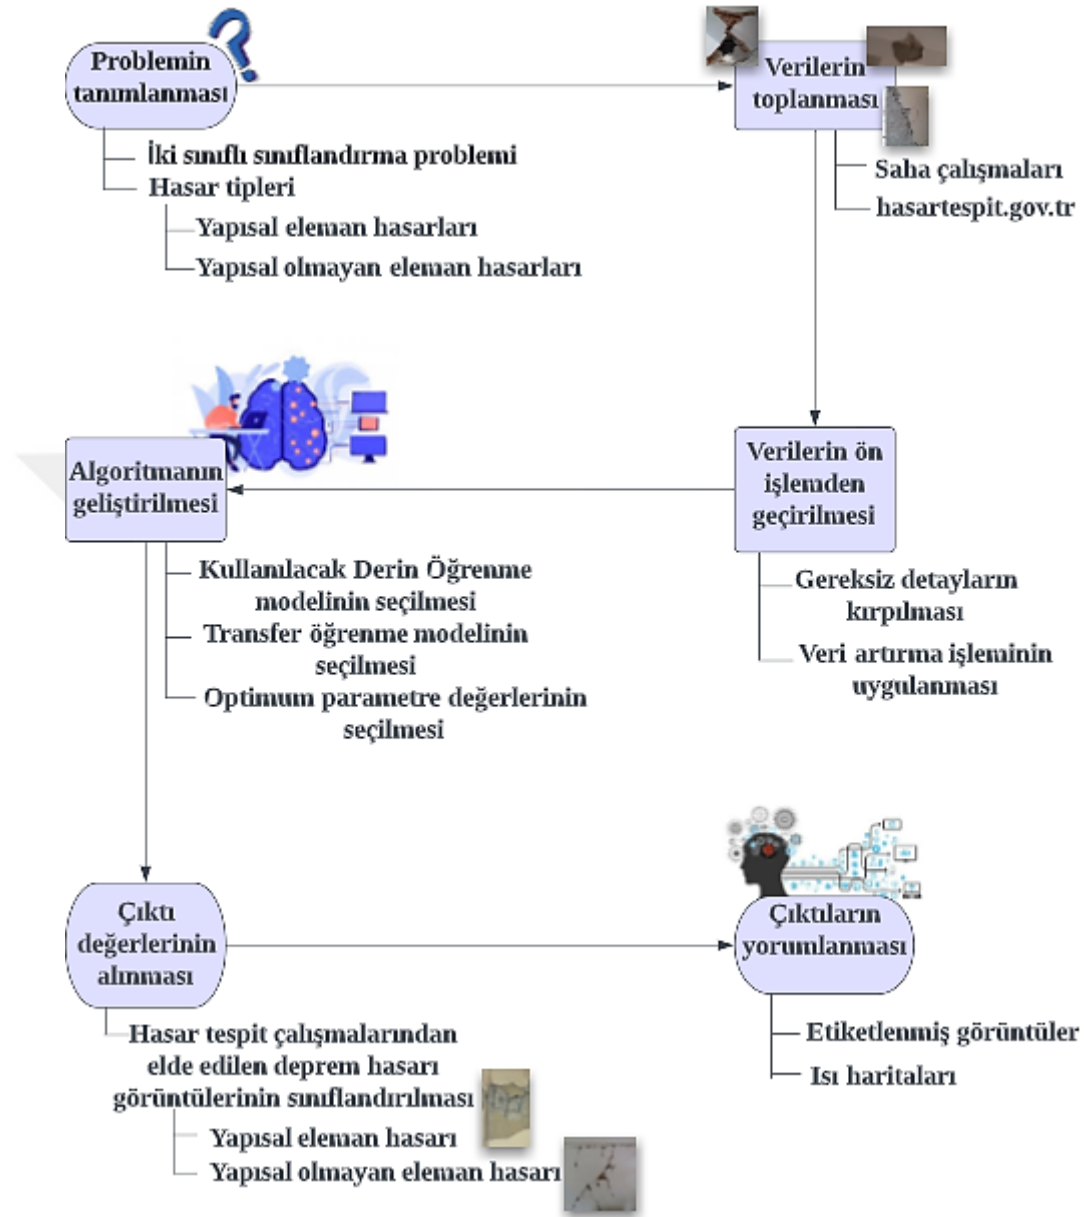
Algoritmadan elde edilen ısı haritaları başarılı odaklanmaların yanında yanlış yere odaklanılan birkaç görüntü olduğunu da göstermiştir. Şekil 5.73'te yanlış odaklanma durumları gösterilmiştir.



Şekil 5.73. Modelin yanlış odaklandığı görüntüler

Yukarıda verilen ilk görüntüde modelin odaklanması gereken kiriş üzerinde diyagonal şekilde oluşmuş olan çatlak olmalıdır. Ancak ısı haritasında da görüldüğü üzere model kirişin alt bölgesine odaklanmış ve buna göre sınıflandırma yapmıştır. İkinci görüntüde yine odaklanması gereken kısım çatlak hattıdır. Fakat model sıvanın dökülüp betonun görüldüğü kısma odaklanmıştır. Bu görüntüler aslında doğru sınıflara ayrılmıştır ancak algoritmanın odaklandığı yerler doğru olmadığından başarılı olarak nitelendirilemez. Modelin %6,88'lik başarısızlık oranının yanında bu şekilde doğru sınıflandırma yapıp aslında başarısız olduğu görüntüler de mevcuttur.

Bu tez çalışmasında takip edilen aşamalar iş-akış şeması olarak Şekil 5.74'te gösterilmiştir.



Şekil 5.74. Tez çalışması iş-akış şeması

6. SONUÇLAR VE ÖNERİLER

Bu çalışmada, depremler sonrası betonarme yapılarda oluşan hasarları yapısal eleman hasarları ve yapısal olmayan eleman hasarları şeklinde sınıflandıran Yapay Zekâ tabanlı bir Derin Öğrenme algoritması geliştirilmiştir. Yapısal eleman hasarlarının tespiti deprem sonrası hasar tespit çalışmalarında oldukça önemli bir yere sahiptir. Fakat bazı durumlarda yapısal eleman hasarı bulunmayıp sadece yapısal olmayan eleman hasarı mevcut olan betonarme yapılarda; binaların boşaltılması, yıkım çalışmalarının başlatılması gibi ciddi kararların verilmesi hem ekonomik açıdan hem de o binada yaşayan insanların barınma ihtiyacı açısından olumsuz sonuçlara sebebiyet vermektedir. Geliştirilen akıllı sistem model ile hem bu olumsuz durumların önüne geçmek amaçlanmıştır. Hasar ayrımı tespit edebilen algoritmanın geliştirilmesinde veri olarak depremler sonrası meydana gelen betonarme yapılardan elde edilen hasar görüntüleri kullanılmıştır. Bunun için son yıllarda ülkemizde meydana gelmiş olan büyük depremler sonrasında sahada yapılan hasar tespit çalışmalarında elde edilen görüntüler kullanılmıştır. Söz konusu depremler 2019 İstanbul (Silivri) ($M_w = 5,8$), 2020 Elazığ (Sivrice) ($M_w = 6,8$) ve 2020 İzmir (Seferihisar) ($M_w = 6,6$) depremleridir. Çalışma kapsamında elde edilen toplam 9.680 adet görüntü yapısal ve yapısal olmayan eleman hasarı olarak iki sınıfa ayrılmıştır. Çalışmadan elde edilen bulgular şunlardır;

- Çalışmada görüntü sınıflandırma işlemi yapılacağından DÖ mimarilerinden bilgisayarla görü alanında en etkin yapı olan ESA seçilmiştir.
- Çok büyük verilerle eğitilmiş transfer öğrenme metotlarından VGG 19 mimarisi seçilmiş, yapısal ve yapısal olmayan hasar sınıflandırma problemine uyarlanmıştır.
- Model için kullanılan veri seti daha önce hiçbir çalışmada kullanılmamış, ilk olarak bu tez çalışması için toparlanmış ve işlenmiştir. Veriler ülkemizde son yıllarda yaşanmış depremler sonrası yapı stoğunda gözlemlenen hasarları kapsamaktadır.
- Çalışma kapsamında toparlanan 9.680 görüntüden 8.228 tanesi modeli eğitmek, 1.452 tanesi ise modeli test etmek amacıyla kullanılmıştır. Test verilerinden elde edilen doğruluk oranı %93,12 olmuştur. Yani çalışmada geliştirilen yapısal eleman hasarlarını yapısal olmayan eleman hasarlarından ayıran sistem %93,12 başarı oranı ile tahmin yapabilmektedir.

- Elde edilen başarı oranı modelin deprem hasarı görüntülerini, yapısal ve yapısal olmayan elemanda oluşan hasar şeklinde sınıflandırmakta oldukça başarılı olduğunu göstermektedir.
- Çalışma, deprem sonrasında yapılan hasar tespit çalışmalarında uzman kişilere yardımcı bir sistem geliştirmeyi amaçlamış ve başarıyla sonuçlanmıştır. Deprem sonrası betonarme binalarda yapılan hasar tespit çalışmalarında zaman zaman yapısal olmayan hasarların yapısal hasarlar ile karıştırılması neticesinde binalar için yanlış kararlar verilebilmekte, bu yanlış kararlar neticesinde ekonomik kayıplar yaşanmaktadır. Özellikle taşıyıcı sisteminde hasar oluşmamış yapılar için verilen yıkım kararları hem ekonomik kayıplara sebebiyet vermekte hem de insanlar için barınma problemini ortaya çıkarmaktadır. Geliştirilen bu algoritma ile hasar sınıflandırma konusunda yüksek başarımlı sağlayan yardımcı bir sistem oluşturulmuş, yapılar için verilen kararlarda ekonomik kazanımlar sağlanması amaçlanmıştır.
- DÖ çalışmalarında en önemli faktörlerden biri veri boyutu ve kalitesidir. Çok daha fazla ve net görüntülerle ileriki çalışmalarda eğitilecek bir model, çok daha başarılı sonuçlara ulaşılmasını sağlayabilecektir.
- Bu tez çalışmasında üzerinde çalışılan deprem hasarlarının olduğu depremler çok büyük magnitüdüde değildir. Geçmişte ülkemizde meydana gelmiş olan 1939 Erzincan depremi ($M_w = 7,9$), 1999 Marmara depremi ($M_w = 7,4$) gibi depremler sırasında betonarme yapılarda meydana gelen hasar görüntülerinin arşivlerine ulaşıldığı takdirde veri dağılımı açısından daha nitelikli bir veri seti elde edilip, özellikle yapısal elemanlardaki hasar görüntüleri çok daha net ve belirgin olacağından daha başarılı bir model oluşturulabilir.
- Betonarme yapılarda çekilen hasar görüntüleri üzerinden sınıflandırma yapan bu gibi modeller deprem hasarları ile sıklıkla karıştırılan korozyon hasarlarını ayırt etmek için de kullanılabilir.
- Bu tez çalışmasında oluşturulan model daha da geliştirilerek yapısal elemanlarda oluşan hasarları kesme, eğilme, burulma gibi hasar tipine göre sınıflandırmak için eğitilebilir. Bu sayede yapısal elemanlarda deprem sonrası yapılacak güçlendirme çalışmaları hakkında araştırmacılara yardımcı bir sistem geliştirilmiş olacaktır.
- Transfer öğrenme metodu olarak seçilen VGG 19 mimarisi başarılı sonuç vermiştir, daha sonraki çalışmalarda buna ek olarak ResNet 52, GoogLeNet gibi

farklı transfer öğrenme metotlarının kullanılması model başarısını daha iyileştirebilir.

- Geliştirilen model, mobil yazılım haline getirilerek çok daha kolay kullanım sağlanabilir. Özellikle resmi kurumlarca yapılan hasar tespit çalışmalarında kullanılan tabletler için entegrasyonu sağlanarak saha çalışmalarında aktif olarak kullanılması mümkün olabilecektir.
- Yapılan bu çalışma, depremlerin ardından hızlı ve doğru bir şekilde yapılması gereken hasar tespit çalışmalarında uzman kişilere yardımcı olacaktır. Daha sonra yapılacak çalışmalarda hasarlı binalara girilmesi tehlikesini ortadan kaldırmak amacıyla İHA veya Dronelarla söz konusu algoritma birleştirilerek yenilikçi bir sistem oluşturulabilir.



KAYNAKLAR

- Abdeljaber, O., Avci, O., Kiranyaz, M. S., Boashash, B., Sodano, H., & Inman, D. J. (2018). 1-D Cnns For Structural Damage Detection: Verification On A Structural Health Monitoring Benchmark Data. *Neurocomputing*, 275, 1308-1317.
- Açııcı, K., 2021, Derin Öğrenme Teknikleri Kullanılarak Kemik Kırığı Tespiti ve Sınıflandırılması, Doktora Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2018, Türkiye’de Afet Yönetimi Ve Doğa Kaynaklı Olay İstatistikleri, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2020, Afet Yönetimi Kapsamında 2019 Yılına Bakış Ve Doğa Kaynaklı Olay İstatistikleri, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2021, 2020 Yılı Doğa Kaynaklı Olay İstatistikleri, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2019, 26 Eylül 2019 Marmara Denizi, Silivri Açıkları (İstanbul) Mw 5.8 Depremine İlişkin Ön Değerlendirme Raporu, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2020, 24 Ocak 2020 Sivrice (Elazığ) Depremi Raporu, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2020, 30 Ekim 2020 Ege Denizi, Seferihisar (İzmir) Açıkları (17,26 Km) Mw 6.6 Depremine İlişkin Ön Değerlendirme Raporu, Ankara.
- Afet Ve Acil Durum Yönetimi Başkanlığı, 2021, 30 Ekim 2020 Sisam Adası (İzmir Seferihisar Açıkları) Mw 6.6 Depremi Raporu, Ankara.
- Akinosho, T. D., Oyedele, L. O., Bilal, M., Ajayi, A. O., Delgado, M. D., Akinade, O. O., & Ahmed, A. A. (2020). Deep learning in the construction industry: A review of present status and future innovations. *Journal of Building Engineering*, 32, 101827.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., ... & Asari, V. K. (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*.
- Arslan, M. H., & Korkmaz, H. H. (2007). What is to be learned from damage and failure of reinforced concrete structures during recent earthquakes in Turkey?. *Engineering Failure Analysis*, 14(1), 1-22.

- Ashames, Y.Y.A., 2020, Derin Öğrenme Yöntemleri Kullanılarak Osteoporozun Belirlenmesi, Yüksek Lisans Tezi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya.
- Atha, D. J., & Jahanshahi, M. R. (2018). Evaluation Of Deep Learning Approaches Based On Convolutional Neural Networks For Corrosion Detection. *Structural Health Monitoring*, 17(5), 1110-1128.
- Avci, O., Abdeljaber, O., Kiranyaz, S., & Inman, D. (2017). Structural Damage Detection In Real Time: Implementation Of 1d Convolutional Neural Networks For Shm Applications. In *Structural Health Monitoring & Damage Detection*, Volume 7 (Pp. 49-54). Springer, Cham.
- Aydilek, F.Y., 2020, Derin Öğrenme Yöntemi ile Ayakkabı Görüntülerinin Sınıflandırılması, Yüksek Lisans Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü, Şanlıurfa.
- Baydan, B., 2021, Derin Öğrenme ile Köpek ve Kedi Tibia Kemikleri Üzerindeki Kırıkların Tespiti ve Sınıflandırılması, Doktora Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Baydilli, Y.Y., 2020, Derin Öğrenme Yöntemleri ile Periferik Yayma Görüntülerinin Analizi ve Sınıflandırılması, Doktora Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.
- Bikçe, M., & Erdem, M. M. (2021). Investigation of construction material quality and workmanship defects of RC buildings collapsed and severely damaged in the 6.8 Mw Sivrice, Elazığ, Turkey earthquake, January 2020. *Bulletin of the New Zealand Society for Earthquake Engineering*, 54(3), 184-196.
- Bingöl, K., Aslı, E. R., Örmecioğlu, H. T., & Arzu, E. R. (2020). Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 2197-2210.
- Boğaziçi Üniversitesi Kandilli Rasathanesi Ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme Ve Değerlendirme Merkezi, 2019, 26 Eylül 2019 Silivri Açıkları-İstanbul (Marmara Denizi) Depremi, İstanbul.
- Boğaziçi Üniversitesi Kandilli Rasathanesi Ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme Ve Değerlendirme Merkezi, 2020, 24 Ocak Sivrice-Elazığ Depremi, İstanbul.

- Boğaziçi Üniversitesi Kandilli Rasathanesi Ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme Ve Değerlendirme Merkezi, 2020, 30 Ekim 2020 Ege Denizi Depremi, İstanbul.
- Cengiz, E., 2020, Endoskopi Görüntülerindeki Poliplerin Derin Öğrenme Algoritması Kullanılarak İncelenmesi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- Cha, Y. J., Choi, W., & Büyüköztürk, O. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil And Infrastructure Engineering*, 32(5), 361-378.
- Cha, Y. J., Choi, W., Suh, G., Mahmoudkhani, S., & Büyüköztürk, O. (2018). Autonomous Structural Visual Inspection Using Region-Based Deep Learning For Detecting Multiple Damage Types. *Computer-Aided Civil And Infrastructure Engineering*, 33(9), 731-747.
- Cogurcu, M. T. (2015). Construction and design defects in the residential buildings and observed earthquake damage types in Turkey. *Natural Hazards and Earth System Sciences*, 15(4), 931-945.
- Coşkun, V., 2020, Derin Öğrenme ile İçecek Şişe Kapağı Üzerindeki Görsellerden Ürün Tipi Tanıma, Yüksek Lisans Tezi, Beykent Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul.
- Coza, H., 2003, Betonarme Yapılarda Gözlenen Deprem Hasarları ve Nedenleri, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Cuşkun, Y., 2019, Beyin Metastazlarının Derin Öğrenme ile Sınıflandırılması, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Çakıroğlu, M. A., & Süzen, A. A. Assessment And Application Of Deep Learning Algorithms In Civil Engineering. *El-Cezeri Journal Of Science And Engineering*, 7(2), 906-922.
- Çınar, A. K., Ekici, Y., & Baysan, N. 30 Ekim 2020 Ege Denizi Depreminin Düşündürdükleri Critics on 30 October 2020 Earthquake.
- Çınar, U.K., 2020, Derin Öğrenme Algoritmalarını Kullanarak Derin Öğrenme, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Çirak, İ. F. (2011). Betonarme binalarda gözlenen hasarlar, nedenleri ve öneriler. *Uluslararası Teknolojik Bilimler Dergisi*, 3(3), 62-71.

- Darıcı M.B., 2020, Göğüs Kafesi Röntgen Görüntülerinde Derin Öğrenme Metoduyla Zatürre Hastalığının Tanısı, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Demir, A., Çiftçioğlu, A. Ö., Başarı, E., Doğan, E., Nohutcu, H., Bozkurt, M. B., ... & Altıok, T. Y. (2020). İzmir (Seferihisar-Sisam) Depremine Sismik Karakteristiği ve Meydana Gelen Yapısal Hasarların İncelenmesi. Teknik Rapor. Manisa Celal Bayar Üniversitesi İnşaat Mühendisliği.
- Demirkol, Z., 2019, Herkes için Yapay Zekâ, Devrim Yalkut, İstanbul.
- Dogan, G., Ecemis, A. S., Korkmaz, S. Z., Arslan, M. H., & Korkmaz, H. H. (2021). Buildings Damages after Elazığ, Turkey Earthquake on January 24, 2020. *Natural Hazards*, 109(1), 161-200.
- Elman, J. L. (1991). Distributed representations, simple recurrent networks, and grammatical structure. *Machine learning*, 7(2), 195-225.
- Er, Ş. B., Aykaç, S., & Can, H., (2014). Betonarme Zayıf Kolon-Kiriş Birleşimlerinin Davranışı. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 29(3).
- Eyidoğan, H. (2020). Report on the seismological characteristics and effects of the 30 October 2020 Samos-Kuşadası Bay earthquake (Mw7. 0) in the western Aegean Sea. ResearchGate Preprint.
- Feng, C., Zhang, H., Wang, S., Li, Y., Wang, H., & Yan, F. (2019). Structural damage detection using deep convolutional neural network and transfer learning. *KSCE Journal of Civil Engineering*, 23(10), 4493-4502.
- Gao, Y., & Mosalam, K. M. (2018). Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering*, 33(9), 748-768.
- Ghosh Mondal, T., Jahanshahi, M. R., Wu, R. T., & Wu, Z. Y. (2020). Deep learning-based multi-class damage detection for autonomous post-disaster reconnaissance. *Structural Control and Health Monitoring*, 27(4), e2507.
- Gülgün, O.D., 2020, Derin Öğrenme Yöntemleri Kullanılarak Tıbbi Görüntülerden Teşhis, Yüksek Lisans Tezi, Mersin Üniversitesi Fen Bilimleri Enstitüsü, Mersin.
- Güney, Y., 2012, Deprem ve Yapı İlişkisi, Eskişehir.
- Güngen, C., 2020, Beyin Tümörlerinin Derin Öğrenme ile Manyetik Rezonans Görüntülerinden Sınıflandırılması, Yüksek Lisans Tezi, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Sivas.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016, October). Identity mappings in deep residual networks. In European conference on computer vision (pp. 630-645). Springer, Cham.
- Hinton, G. E. (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hoskere, V., Narazaki, Y., Hoang, T. A., & Spencer Jr, B. F. (2018). Towards automated post-earthquake inspections with deep learning-based condition-aware models. arXiv preprint arXiv:1809.09195.
- Hubel, D. H., & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of physiology*, 160(1), 106.
- Inik, Ö., & Ülker, E. (2022). Optimization of deep learning based segmentation method. *Soft Computing*, 26(7), 3329-3344.
- Işık, E., & Özdemir, M. (2016). Betonarme Yapılarda Güçlü Kiriş-Zayıf Kolon Durumunun Yapı Performansına Etkisi. In 1st International Mediterranean Science and Engineering Congress (IMSEC) (pp. 1-10).
- Ismail, A. A., Wood, T., & Bravo, H. C. (2018). Improving long-horizon forecasts with expectation-biased LSTM networks. arXiv preprint arXiv:1804.06776.
- Karaesmen, E., 2002, Öncesiyle Sonrasıyla Deprem, Ankara.
- Kılınç, H. Ç. Uzun-Kısa Süreli Bellek Ağlarının Nehir Akım Tahmininde Farklı Optimizasyonlarla Karşılaştırılması Ve Tekil Spektrum Analizinin Etkisi. *Avrupa Bilim Ve Teknoloji Dergisi*, (23), 248-253.
- Kiriş, R., 2021, Görüntü Segmentasyonu İle Entegre Edilmiş Evrişimli Sinir Ağları İle Deprem Sonrası Hasarlı Binaların Otomatik Olarak Tespiti, Yüksek Lisans Tezi, Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü, Gümüşhane.
- Korkmaz, E. (2020). Betonarme kirişlerin içerisinde geçen tesisat borularının eğilme dayanımına etkisi (Master's thesis, Fen Bilimleri Enstitüsü).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- Li, Y., Zhang, Y., & Ji, Y. (2014). Privacy-preserving restricted boltzmann machine. *Computational and mathematical methods in medicine*, 2014.

- Lin, Y. Z., Nie, Z. H., & Ma, H. W. (2017). Structural Damage Detection With Automatic Feature-Extraction Through Deep Learning. *Computer-Aided Civil And Infrastructure Engineering*, 32(12), 1025-1046.
- Malkoçoğlu, A.B., 2020, Akut Lenfoblastik Lösemi Hücrelerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü, Samsun.
- Mangalathu, S., & Burton, H. V. (2019). Deep Learning-Based Classification Of Earthquake-Impacted Buildings Using Textual Damage Descriptions. *International Journal Of Disaster Risk Reduction*, 36, 101111.
- Mertol, A., Mertol, H.C. (2002). Deprem Mühendisliği Depreme Dayanıklı Yapı Tasarımı.
- Nahata, D., Mulchandani, H. K., Bansal, S., & Muthukumar, G. (2019). Post-Earthquake Assessment of Buildings Using Deep Learning. arXiv preprint arXiv:1907.07877.
- Nakano, Y., Maeda, M., Kuramoto, H., & Murakami, M. (2004, August). Guideline for post-earthquake damage evaluation and rehabilitation of RC buildings in Japan. In *13th World Conference on Earthquake Engineering* (No. 124).
- Özmen, H. B., İnel, M. & Çaycı, B. T. 23 Ekim Ve 9 Kasım 2011 Van Depremleri Yapısal Hasar Değerlendirme Raporu.
- Özyürek, K., & Beyen, K. (2019). Farklı Özellikleri Olan Depremler Altında Zayıf Kat Ve Yumuşak Kat Düzensizliklerinin İncelenmesi. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 1(1).
- Pampal, S., Özmen, B. (2007). Türkiye'nin Deprem Gerçeği: Deprem Bölgeleri Haritaları Ve Deprem Yönetmeliklerinin Tarihsel Gelişimi Gerçeği. Ankara.
- Pathirage, C. S. N., Li, J., Li, L., Hao, H., Liu, W., & Ni, P. (2018). Structural damage identification based on autoencoder neural networks and deep learning. *Engineering structures*, 172, 13-28.
- Patterson, B., Leone, G., Pantoja, M., & Behrouzi, A. A. (2018). Deep learning for automated image classification of seismic damage to built infrastructure. In *Eleventh US National Conference on Earthquake Engineering*.
- Qanbar, M.M., 2019, Derin Öğrenme Yaklaşımı ile Malaria (Sıtma) Hastalığı Görüntülerinin Sınıflandırılması, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

- Salakhutdinov, R., Mnih, A., & Hinton, G. (2007, June). Restricted Boltzmann machines for collaborative filtering. In Proceedings of the 24th international conference on Machine learning (pp. 791-798).
- Sayın, E., Yön, B., Onat, O., Gör, M., Öncü, M. E., Tuğrul Tunç, E., & Calayır, Y. (2021). 24 January 2020 Sivrice-Elazığ, Turkey earthquake: geotechnical evaluation and performance of structures. *Bulletin of Earthquake Engineering*, 19(2), 657-684.
- Ser, G. & Bati, C. T. (2019). Derin sinir ağları ile en iyi modelin belirlenmesi: mantar verileri üzerine Keras uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417.
- Seyyarer, E., Ayata, F., Uçkan, T., & Karci, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kiyaslanması. *Computer Science*, 5(2), 90-98.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sucu, İ., Ataman, E. (2020). Dijital Evrenin Yeni Dünyası Olarak Yapay Zeka Ve Her Filmi Üzerine Bir Çalışma. *Yeni Medya Elektronik Dergisi*, 4(1), 40-52.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- Şahbaz, U., 2005, Planda Çıkıntı Düzensizliğine Sahip Betonarme Yapıların Deprem Yüğü Etkisi Altında Karşılaştırmalı Analizi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Şıkoğlu, E., & Güney, Y. 24 Ocak 2020 Sivrice (Elazığ) Depremi'nin Kent Merkezindeki Yansıması Üzerine Coğrafi Bir Değerlendirme. *Resilience*, 4(2), 275-292.
- Şirin, C., 2006, Yapılarda Oluşan Hasar Biçimleri Ve Nedenleri Ve Yapıların Onarım Ve Güçlendirilmesi Teknikleri İle Bir Yapının Güçlendirilmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Tan, M.E., 2000, Depreme Dayanıklı Yapı Tasarımı, Ankara.
- Tan, Z., 2019, Derin Öğrenme Yardımıyla Araç Sınıflandırma, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

- Terzi, M., & Elçi E., (2016). Perde-çerçeveveli betonarme yapılarda A2 türü düzensizliğin kesit tesirlerine etkisi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 11(1), 83-94.
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In Handbook of research on machine learning applications and trends: algorithms, methods, and techniques (pp. 242-264). IGI global.
- Tuna, M. E., 2000, Depreme Dayanıklı Yapı Tasarımı, Ankara.
- Türkiye Deprem Yönetmeliği, 2007.
- Türkiye Bina Deprem Yönetmeliği, 2018.
- URL 1: <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/>
- URL 2: <https://trends.google.com/trends/explore?date=2012-10-04%202022-05-10&q=deep%20learning>
- URL 3: <https://link.springer.com/article/10.1007/s12145-019-00434-8>
- URL 4: <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>
- URL 5: <https://www.linkedin.com/pulse/derin-%C3%B6%C4%9Frenme-uygulamalar%C4%B1ndatemelkavramlarskorve%C3%A7arkac%C4%B1/?originalSubdomain=tr>
- URL 6: <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>
- URL 7: <https://medium.com/@gulcanogundur/overfitting-a%C5%9F%C4%B1r%C4%B1-%C3%B6%C4%9Frenme-underfitting-eksik->
- URL 8: https://www.researchgate.net/figure/Data-augmentation-using-semantic-preserving-transformation-for-SBIR_fig2_319413978
- URL 9: <https://medium.com/@mohamedchetoui/grad-cam-gradient-weighted-class-activation-mapping-ffd72742243a>
- URL 10: <https://towardsai.net/p/machine-learning/the-architecture-and-implementation-of-vgg-16>
- URL 11: <https://towardsdatascience.com/an-intuitive-guide-to-deep-network-architectures-65fdc477db41>
- URL 12: <https://towardsdatascience.com/review-resnet-winner-of-ilsvrc-2015-image-classification-localization-detection-e39402bfa5d8>
- URL 13: <https://paperswithcode.com/method/inception-v2>
- URL 14: <https://www.vargonen.com/blog/python-nedir/>
- URL 15: <https://mesutpiskin.com/blog/opencv-nedir.html>

URL 16: <https://depem.afad.gov.tr/depem-tehlike-haritasi>

URL 17: <https://pngmerkezdotorg.wordpress.com/2020/06/18/yapisal-duzensizlikler-2/>

URL 18: https://santiyede.com/duvar-catlaklari-olusma-nedenleri/#Temel_Oturmaları_Sonucu_Olusan_Duvar_Catlakları

URL 19: https://tr.wikipedia.org/wiki/2019_%C4%B0stanbul_depremi

URL 20: <https://www.aa.com.tr/tr/gundem/istanbulda-7-5lik-depremde-491-bin-binanin-hasar-almasi-bekleniyor/2336517>

Xu, Y., Wei, S., Bao, Y., & Li, H. (2019). Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network. *Structural Control and Health Monitoring*, 26(3), e2313.

Yakut, A., Sucuoğlu, H., Binici, B., Canbay, E., Donmez, C., İlki, A., & Ay, B. Ö. (2021). Performance of structures in İzmir after the Samos island earthquake. *Bulletin of Earthquake Engineering*, 1-26.

Yapı, F. Ü. 24 Ocak 2020 Mw 6.8 Sivrice Depremi Elazığ Bölgesi Yapısal Hasarlar İnceleme Ve Değerlendirme Raporu.

Yaseen, Z. M., Afan, H. A., & Tran, M. T. (2018, April). Beam-Column Joint Shear Prediction Using Hybridized Deep Learning Neural Network With Genetic Algorithm. In *Iop Conference Series: Earth And Environmental Science* (Vol. 143, No. 1, P. 012025). Iop Publishing.

Yılmaz, E., 2019, Depremlerde Meydana Gelen Tipik Betonarme Yapı Hasarlarına 2018 Türkiye Bina Deprem Yönetmeliğine Göre Alınabilecek Önlemler, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Deprem Mühendisliği ve Afet Yönetimi Enstitüsü, İstanbul.

Yılmaz, G., Umu, S.U., Yapılarda Hasar Ders Notları, Eskişehir.

Yön, B., Sayın, E. Kısa Kolon Teşkilinin Yapı Hasarlarına Etkisi. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 24(1), 241-259.

Yüksel, İ. (2008). Betonarme Binaların Deprem Sonrası Acil Hasar Değerlendirmeleri. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 24(1), 260-276.

Yüzer, N. (2003). Betonarme Yapılarda Korozyon Ölçüm Yöntemleri Ve Hasar Tespiti.

Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In *European conference on computer vision* (pp. 818-833). Springer, Cham.

Zülfikar, A. C., Tekin, S., Akcan, S. O., & Gök, M. G. (2020). 26 Eylül 2019 Silivri Açıkları (Marmara Denizi) Depreminin Kuvvetli Yer Hareketi Verilerinin

Değerlendirilmesi. Journal Of The Institute Of Science And Technology, 10(3), 1720-1736.



