



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEVCUT BETONARME BİNALARIN HIZLI SİSMİK DEĞERLENDİRİLMESİNDE
KULLANILAN BAZI GEOMETRİK PARAMETRELERİN ÖN EĞİTİMLİ
KONVOLÜSYONEL SİNİR AĞLARI İLE BELİRLENMESİ

Muhammet Yuşa EKİCİ

DOKTORA TEZİ

İnşaat Mühendisliği Anabilim Dalı

Ekim-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Muhammet Yuşa EKİCİ tarafından hazırlanan “Mevcut Betonarme Binaların Hızlı Sismik Değerlendirilmesinde Kullanılan Bazı Geometrik Parametrelerin Ön Eğitimli Konvolüsyonel Sınır Ağları ile Belirlenmesi” adlı tez çalışması 06/10/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü İnşaat Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Ali KÖKEN

Danışman

Prof. Dr. Musa Hakan ARSLAN

Üye

Dr. Öğr. Üyesi İbrahim Hakkı ERKAN

Üye

Dr. Öğr. Üyesi Ali Serdar ECEMİŞ

Üye

Dr. Öğr. Üyesi Ahmet ÖZKİŞ

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
LEE Müdürü

Bu tez çalışması Konya Teknik Üniversitesi BAP Koordinatörlüğü tarafından 211104060 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.

Muhammet Yuşa EKİCİ

Tarih: 06/10/2022

ÖZET

DOKTORA TEZİ

MEVCUT BETONARME BİNALARIN HIZLI SİSMİK DEĞERLENDİRİLMESİNDE KULLANILAN BAZI GEOMETRİK PARAMETRELERİN ÖN EĞİTİMLİ KONVOLÜSYONEL SİNİR AĞLARI İLE BELİRLENMESİ

Muhammet Yuşa EKİCİ

**Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü
İnşaat Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Musa Hakan ARSLAN
Yardımcı Danışman: Dr. Öğr. Üyesi Amir YAVARIABDI**

2022, 224 Sayfa

Jüri

**Prof. Dr. Musa Hakan ARSLAN
Prof. Dr. Ali KÖKEN
Dr. Öğr. Üyesi İbrahim Hakkı ERKAN
Dr. Öğr. Üyesi Ali Serdar ECEMİŞ
Dr. Öğr. Üyesi Ahmet ÖZKİŞ**

Önemli deprem kuşağı üzerinde yer alan ülkemizde, olası depremlerden önce mevcut binaların risk analizlerinin yapılmış ve proaktif önlemlerin alınmış olması son derece önem arz etmektedir. Buna bağlı olarak Türkiye’de deprem öncesi mevcut binaların risk analizi için şehirlerde bulunan özellikle konut türü yüz binlerce binanın incelenmesine ihtiyaç duyulmaktadır. Geliştirilen birçok hızlı sismik değerlendirme yöntemi olmasına rağmen binaların deprem risk öncelik sırasının belirlenmesi, yapı envanteri içerisinde yer alan konut türü bina sayısının çok fazla olması nedeniyle oldukça büyük bir bütçe ve zaman gerektirmektedir. Ayrıca incelenecek bina sayısının fazla olması yeterli donanıma sahip çok sayıda teknik uzman görevlendirilmesine de sebep olacaktır. Teknik uzmanların yapacakları incelemelerde uzmanın tecrübesine bağlı farklılıklar da oluşabilecektir. Bunların yanı sıra deprem risk analizinin birbirinden farklı ve oldukça fazla parametreye bağlı olması da önemli bir problemdir. Deprem risk analizi gibi hayati bir konuda verilen kararlarda değerlendirmenin mümkün olduğunca standart yapılması, kararların daha hızlı ve ölçülebilir şekilde alınması oldukça önemlidir. Bu bağlamda Türkiye için oldukça kritik bir konu olan mevcut binaların deprem risk analizlerinin sağlıklı bir şekilde gerçekleştirilmesinde akıllı sistemlerden faydalanarak mümkün olduğunca doğru sonuçlara varmak oldukça önemlidir. Özellikle son yıllarda sayıca fazla olan ve çoklu parametrelere bağlı karmaşık mühendislik problemlerin çözümünde akıllı sistemler sıklıkla kullanılmaya başlanmıştır. Bu motivasyondan hareketle bu tezde; konut türü betonarme binaların deprem öncesi risk analizinde uzman mühendise yardımcı olacak (ya da teknik uzman yokluğunda karar vermeyi kolaylaştıracak) ve risk önceliklendirilmesinde kullanılacak parametrelerden olan ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi varlığı durumlarını bina cephe görselleri üzerinden tahmin edebilen, Ön Eğitilmiş Evrişimli (Konvolüsyonel) Sinir Ağları (CNN) yapılarının (DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50) bazı katmanlarında düzenlemeler yapılması suretiyle analizler icra edilmiş ve analiz sonuçları mukayese edilmiştir. Bu bağlamda elde edilen analiz sonuçları değerlendirildiğinde; Ön Eğitilmiş KSA mimarilerinin bina cephe görselleri üzerinden söz konusu parametreleri ikili sınıflandırma stratejisi uyarınca %97’ye, çok sınıflı sınıflandırma stratejileri uyarınca da %79’a varan doğruluk oranı ile

oldukça hızlı bir şekilde tespit edebildiği görülmüştür. Ayrıca, tez çalışmasında kullanılan Ön Eğitimli KSA mimarilerinin seçilen geometrik parametrelerin tespiti açısından mevcut betonarme binalar için kullanılabilir olduğu görülmüştür.

Anahtar kelimeler: Deprem, Hızlı Sismik Değerlendirme, Yapısal Parametre, Derin Öğrenme, Ön Eğitimli Evrişimli Sinir Ağları.



ABSTRACT

PhD THESIS

DETERMINATION OF SOME GEOMETRIC PARAMETERS USED IN RAPID SEISMIC EVALUATION OF EXISTING REINFORCED CONCRETE BUILDINGS WITH PRE- TRAINED CONVOLUTIONAL NEURAL NETWORKS

Muhammet Yuşa EKİCİ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF KONYA
TECHNIC UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN CIVIL ENGINEERING**

**Advisor: Prof. Dr. Musa Hakan ARSLAN
Co-Advisor: Asst. Prof. Dr. Amir YAVARIABDI**

2022, 224 Pages

**Jury
Prof. Dr. Musa Hakan ARSLAN
Prof. Dr. Ali KÖKEN
Asst. Prof. Dr. İbrahim Hakkı ERKAN
Asst. Prof. Dr. Ali Serdar ECEMİŞ
Asst. Prof. Dr. Ahmet ÖZKİŞ**

In our country, which is located in a seismic region, it is extremely important that the risk analyzes of existing buildings have been conducted and necessary precautions have been taken before possible earthquakes. Accordingly located in the city for a rapid seismic analysis of the existing residential buildings before the earthquake in Turkey, hundreds of thousands of buildings are required to be examined. Despite the rapid seismic assessment methods developed, determining the earthquake risk priority order of buildings requires a considerable cost and time due to the large number of structural inventories. In addition, the huge number of buildings to be examined will result in the appointment of a large number of technical experts with sufficient equipment. There may also be differences in the surveys made by the technical experts, depending on the experience of the expert. In addition to these, it is also an important problem that earthquake risk analysis is different from each other and depends on quite a lot of parameters. It is very important to make the evaluation as standard as possible in the decisions made on a vital issue such as earthquake risk analysis, and to take the decisions in a faster and measurable way. In this context, it is very important to reach accurate results as much as possible by making use of smart systems in performing earthquake risk analyzes of existing buildings, which is a critical issue for Turkey. Especially in recent years, smart systems have started to be used frequently in the solution of complex engineering problems related to multiple parameters. Based on this motivation, in this thesis; analyzes were carried out and analysis results were compared by making arrangements in some layers of Pre-Trained Convolutional Neural Networks structures (DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50), which can predict heavy overhang, adjacent regularity and sloping land presence, which are the parameters to be used in risk prioritization and will assist the expert engineer (or facilitate decision-making in the absence of an expert) in the pre-earthquake risk analysis of residential type reinforced concrete buildings. When the analysis results obtained in this context are evaluated; It has been observed that Pre-Trained CNN architectures can detect these parameters very quickly, with an accuracy rate of up to 97% according to the binary classification strategy and up to 79% according to the multi-class classification strategies, on the building facade images.

In addition, it has been seen that the Pre-Trained CNN architectures used in the thesis study can be used for existing reinforced concrete buildings in terms of determining the selected geometric parameters.

Keywords: Earthquake, Rapid Seismic Assessment, Structural Parameter, Deep Learning, Pre-Trained Convolutional Neural Networks.



ÖNSÖZ

Tez çalışmam boyunca yol gösterici kimliğiyle yardımcı olan çok kıymetli danışman hocam Prof. Dr. Musa Hakan ARSLAN'a, lisans, yüksek lisans ve doktora öğrenimim boyunca bilgilerini aktaran ve üzerimde emeği olan tüm saygıdeğer hocalarıma, çalışmam boyunca desteklerini esirgemeyerek bina cephe görsellerinin toplanmasında yardımcı olan meslektaşlarım Yük. İnş. Müh. Fatih Mehmet AŞIK ve İnş. Müh. Selim ÇELİK'e, içtenlikle teşekkür ederim.

Bu tez çalışması Prof. Dr. Musa Hakan ARSLAN, Dr. Öğr. Üyesi Amir YAVARIABDI, Dr. Öğr. Üyesi Gamze DOĞAN, İnş. Yük. Müh. Muhammet Yuşa EKİCİ ve İnş. Yük. Müh. Fatih Mehmet AŞIK tarafından hazırlanarak 2021 yılında Türk Patent Enstitüsüne sunulan ve halen inceleme sürecinde olan patent başvurusu kapsamında hedeflenen algoritmaların birinci kısmını içermektedir. Bu bağlamda tezin olgunlaşmasını sağlayan söz konusu patent başvurusu kapsamında emeği geçen hocalarıma da teşekkür ederim.

Ayrıca tez çalışması sürecinde TİK toplantılarında yol gösterici ve destekleyici olan Prof. Dr. Ali KÖKEN ve Dr. Öğr. Üyesi Ali Serdar ECEMİŞ hocalarıma da teşekkür ederim.

Bu çalışmam sırasında bana her türlü maddi ve manevi desteği olan, haklarını hiçbir zaman ödeyemeyeceğim sevgili eşim Cennet EKİCİ'ye, sevgili babam Bülent EKİCİ'ye ve sevgili annem Nezahat EKİCİ'ye ve çalışmalarımı muziplikleri ile baltalayan sevgili oğlum Ertuğrul Buğra EKİCİ'ye sonsuz teşekkürlerimi sunarım.

Muhammet Yuşa EKİCİ
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
ÖNSÖZ	viii
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	9
2.1. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemlerine İlişkin Kaynak Araştırması	9
2.2. İnşaat Mühendisliği ve Yapay Zekayı Bütünleştiren Çalışmalara İlişkin Kaynak Araştırması	22
2.3. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemlerini ve Yapay Zekayı Bütünleştiren Kaynak Araştırması	28
3. YAYGIN DEPREM HASARLARI VE DEPREM ÖNCESİ HIZLI DEĞERLENDİRME YÖNTEMLERİ	37
3.1. Deprem Hasarları ve Nedenleri	37
3.1.1. Planda düzensizlik kaynaklı hasarlar	39
3.1.2. Düşey doğrultuda düzensizlik kaynaklı hasarlar	43
3.1.3. Kısa kolon kaynaklı hasarlar	46
3.1.4. Bitişik nizam inşa edilmiş binalar kaynaklı hasarlar	47
3.1.5. Donatı kaynaklı hasarlar	48
3.1.6. Beton kalitesi kaynaklı hasarlar	49
3.1.7. Rijitlik yetersizliği kaynaklı hasarlar	51
3.1.8. Zemin kaynaklı hasarlar	52
3.1.9. Korozyon kaynaklı hasarlar	54
3.1.10. Zayıf kolon-kuvvetli kiriş kaynaklı hasarlar	55
3.2. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemleri.....	56
3.2.1. FEMA-154 yöntemi	58
3.2.2. Yakut yöntemi	58
3.2.3. P25 yöntemi.....	59
3.2.4. RVS (Sucuoğlu) yöntemi	62
3.2.5. RYTEİE-2019 yöntemi	62
3.2.6. DURTES yöntemi	63
3.2.7. AURAP yöntemi	64
3.2.8. PERA yöntemi.....	66
3.2.9. Japon sismik indeks yöntemi.....	70
3.2.10. Kanada sismik tarama yöntemi	73
4. YAPAY ZEKA TANIMI VE TARİHSEL GELİŞİMİ	80
4.1. Yapay Sinir Ağları	80
4.1.1. Aktivasyon fonksiyonları	83
4.1.2. YSA kullanım alanları.....	85
4.1.3. YSA özellikleri.....	85

4.1.4. YSA öğrenme türleri	90
4.1.5. YSA ağ yapıları	91
4.1.6. YSA katmanları	91
4.2. Konvolüsyonel (Evrışimli) Sinir Ağları	92
4.2.1. Giriş katmanı	92
4.2.2. Konvolüsyon katmanı	93
4.2.3. RELU (Düzleştirilmiş doğrusal birim) katmanı	96
4.2.4. Havuzlama (Pooling) katmanı	97
4.2.5. Tam bağlı katman	98
4.2.6. Seyreltme (Dropout) katmanı	98
4.2.7. SoftMax aktivasyon fonksiyonu (katmanı)	99
4.2.8. Sınıflandırma katmanı	100
4.3. Transfer Öğrenme (Ön Eğitimli KSA Yapıları)	100
4.3.1. VGG-19	101
4.3.2. ResNet-50/ResNet-101	102
4.3.3. Inception ResNetV2	104
4.3.4. SqueezeNet	109
4.3.5. Xception	112
4.3.6. ShuffleNet	115
4.3.7. DarkNet-53	118
4.3.8. NasNet Large	119
4.3.9. EfficientNet	123
4.4. Konvolüsyonel Sinir Ağlarını Değerlendirmek için Kullanılan Metrikler	125
5. MATERYAL VE YÖNTEM	128
6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	148
7. SONUÇLAR VE ÖNERİLER	203
7.1. Sonuçlar	204
7.2. Öneriler	207
8. KAYNAKLAR	211
9. ÖZGEÇMİŞ	224

SİMGELER VE KISALTMALAR

Simgeler

A	: Depremsellik faktörü
a_1	: Yer deęiřtirme uyum katsayısı
a_2	: Kısa kolon bulunması durumunda perdeler için yer deęiřtirme uyum katsayısı
a_3	: Kısa kolon bulunması durumunda perdeler için yer deęiřtirme uyum katsayısı
A_0	: Etkin yer ivme katsayısı
A_c	: Kesit alanı
A_{c1}	: Eleman net yükseklięi/kesit derinlięi < 6 olan kolonların toplam enkesit alanı
A_{c2}	: Eleman net yükseklięi/kesit derinlięi > 6 olan kolonların toplam enkesit alanı
A_i	: Herhangi bir kattaki toplam kat alanı
A_s	: Kesme donatısı toplam kesit alanı
A_{sc}	: Kısa kolonların toplam enkesit alanı
A_{w1}	: İki tarafından başlıklı perdelerin toplam enkesit alanı
A_{w2}	: Bir tarafından başlıklı perdelerin toplam enkesit alanı
A_{w3}	: Başlıksız perdelerin toplam enkesit alanı
B	: Zemin faktörü
b_w	: Kolon geniřlięi
C	: Tařıyıcı sistem katsayısı
CA	: Yapısal düzensizlik katsayısı
CAF	: Düşeyde süreksizlik düzensizlięi katsayısı
CAP	: Burulma düzensizlięi katsayısı
CAS	: Yumuřak kat katsayısı
CASC	: Kısa kolon katsayısı
C_c	: Kolonların taşıma gücü
CM	: İnřa kalitesi katsayısı
C_{sc}	: Kısa kolonların taşıma gücü
C_T	: Momente dayanıklı çerçeve sistemler için bir katsayı
C_w	: Perdelerin taşıma gücü
D	: Döřeme sistemi katsayısı
d	: Kolon faydalı yükseklięi
E	: Yapısal düzensizlik katsayısı
E_0	: Ana yapısal performans indeksi
E_s	: Ana karşılařtırma indeksi
E_c	: Betonun elastisite modülü
F	: Binada yařayanların katsayısı
FAS	: Nihai deęerlendirme puanı
f_c	: Binanın MPa cinsinden basınç dayanımı
f_{ckj}	: j günlük betonun karakteristik silindir dayanımını
f_{ct}	: Binanın MPa cinsinden çekme dayanımı
F_{sc}	: Kısa kolon süneklięine baęlı katsayı
F_w	: Perde süneklięine baęlı katsayısı
f_{ywm}	: Enine donatı akma dayanımı
G	: Binanın genel durumu ile ilgili katsayı (Kanada Sismik Tarama Yöntemi)
G	: Zemin katsayısı (Japon Sismik İndeks Yöntemi)
H	: Yapısal olmayan faktörler
H_N	: Bina yükseklięi

H_n	: Bina yüksekliđi
h_0	: Bina yüksekliđi düzeltme çarpanı
I	: Bina önem katsayısı
I	: Eylemsizlik momenti
I_s	: Yapısal sismik performans indeksi
I_{so}	: Karşılaştırma indeksi
I_b	: Kritik katta en çok tekrar eden kirişin atalet momenti
I_x	: Bina taban alanını içine alan dikdörtgenin x yönündeki atalet momentleri
I_y	: Bina taban alanını içine alan dikdörtgenin y yönündeki atalet momentleri
i	: Göz önüne alınan kat
j	: Giriş değeri
K_1	: Mukavemet puanı
K_2	: Kusur puanı
k_1-k_2	: Kiriş rijitlik katsayıları
k_c	: Kolon rijitlik katsayısı
L	: Zemin kat yüksekliđi
L_n	: Kolon net yüksekliđi
L_{taban}	: Bina dış aksları arası uzaklık
M_{alt}	: Kolon alt ucunda oluşan moment
M_c	: Kolonlardaki toplam moment
M_d	: Tasarım momenti
M_k	: Kolon moment kapasitesi
$M_{üst}$: Kolon üst ucunda oluşan moment
M_r	: Moment kapasitesi
M_{ri}	: Kirişin sol ucu i 'deki kolon veya perde yüzeyinde f_{cd} ve f_{yd} 'ye göre hesaplanan pozitif veya negatif taşıma gücü moment
M_{rj}	: Kirişin sağ ucu i 'deki kolon veya perde yüzeyinde f_{cd} ve f_{yd} 'ye göre hesaplanan pozitif veya negatif taşıma gücü moment
N	: Kat sayısı
N_d	: Eksenel yük
N_{G+Q}	: Kolonlara etkiyen düşey yüklerden gelen eksenel yükler
n	: Hareketli yük katılım katsayısı
NSI	: Yapısal olmayan indeks
O_i	: Olumsuzluk parametre değeri
O_{pi}	: Olumsuzluk parametre puanı
P_1	: Temel yapısal puanı
P_i	: Her bir göçme puanını ifade eden değer
P_i	: Düzensizliklere bađlı olarak belirlenen cezalandırma katsayıları
p_{ij}	: j sınıfına ait olan i örneğinin olasılığı
P_{min}	: P_i puanlarının en küçüğü
P_w	: Ağırlıklı ortalama puan
q	: Hareketli yük katsayısı
R	: Yapısal sistem davranış katsayısı
RBS	: Göreceli kat puanı
S_D	: Plandaki kat yükseklikleri vb. düzensizlikler dikkate alınarak hesaplanan katsayı
SI	: Yapısal indeks
SPI	: Sismik öncelik indeksi

SSF	: Yapısal güvenlik faktörü
s	: Etriye aralığı
s	: Kolonların bina içindeki konumlarına göre kodları
S(τ)	: Spektrum katsayısı
sınıf _j	: Çıkış değeri
sf _j	: Softmax aktivasyon fonksiyonu
sf _q	: Softmax katmanındaki her bir yapay sinir
T	: Zamana bağlı etki katsayısı
t	: Topoğrafik konum katsayısı
T _A -T _B	: Karakteristik spektrum periyotları
U	: Kullanım katsayısı
V	: Kolon kesme kuvveti
V _b	: Taban kesme kuvveti
V _c	: Bina taban kesme dayanımı
V _c	: Betonun kesme dayanımına betonun katkısı
V _d	: Dizayn kesme kuvveti
V _e	: Kolonlarda oluşabilecek maksimum kesme kuvveti
V _r	: Kolon, kiriş veya perde kesitinin kesme dayanımı
V _{si}	: Güvenlik puanı
VSM _i	: Güvenlik puan çarpanı
V _x	: Binanın x doğrultusundaki kesme dayanımı
V _w	: Betonun kesme dayanımına kesme donatısının katkısı
V _y	: Binanın y doğrultusundaki kesme dayanımı
V _{yw}	: Dolgu duvarların yatay yük taşıma kapasitesine katkısını da içeren bina dayanım değeri
W	: Yaklaşık bina ağırlığı
W	: Göz önüne alınan kat üzerindeki bina ağırlığı
y	: Rijitlik oranına bağlı bir katsayı
y _{ij}	: i örneğinin y sınıfına ait olup olmaması durumu
y _j	: Ölçülen değer
ŷ _j	: Öngörülen değer
Z	: Bölge katsayısı
β	: P _i göçme kriterlerinin birbirleri ile etkileşimini temsil eden çarpan
λ	: Eşdeğer deprem yükü azaltma katsayısı
δ	: Kat etkin görelî kat ötelemesi
ρ	: Ortalama donatı oranı
$\sum A_c$: Kritik kat enine kesitindeki toplam kolon alanı
$\sum A_{swx}$: Kritik kat enine kesitindeki x doğrultusuna paralel duvar alanı
$\sum A_{swy}$: Kritik kat enine kesitindeki y doğrultusuna paralel duvar alanı

Kısaltmalar

ABYYHY:	Afet Bölgelerinde Yapılacak Yapılar Hakkında Yönetmelik
AI	: Yapay Zekâ
AIJ	: Japonya Mimari Enstitüsü
ATC	: Uygulamalı Teknoloji Konseyi
AURAP	: Anadolu Üniversitesi Hızlı Değerlendirme Yöntemi
BCPI	: Temel Kapasite İndeksi

BS	: Taban Puan
CCPM	: Çatlak Merkezi Nokta Yöntemi
CG	: Can Güvenliği
CNN	: Evrişimli Sinir Ağları
ÇTB	: Çok Tehlikeli Binalar
DBYBHY	: Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik
DGTY	: Deprem Güvenliği Tarama Yöntemi
DÖ	: Derin Öğrenme
DÖB	: Düşük Öncelikli Binalar
DURTES	: Durum Tespit Yöntemi
EMS	: Avrupa Makrosismik Ölçeği
EOF	: Deneysel Ortogonal Fonksiyon
FEMA	: Federal Acil Durum Yönetim Kurumu
FRCNN	: Daha Hızlı Bölge Evrişimli Sinir Ağları
GDP	: Göreceli Durum Tespit Puanı
GÖ	: Göçme Öncesi
GPR	: Gauss Süreci Regresyonu
HAZUS	: Federal Acil Durum Yönetim Ajansı
HK	: Hemen Kullanım
HPC	: Yüksek Performanslı Beton
İHA	: İnsansız Hava Aracı
JBDPA	: Japonya Bina Afet Önleme Kurumu
LIDAR	: Işık Tespiti ve Uzaklık Tayini
LRN	: Yerel Tepki Normalleştirilmesi
MASW	: Yüzey Dalgalarının Çok Kanallı Analizi
MÖ	: Makine Öğrenmesi
MR	: Karışık Gerçeklik
NSI	: Yapısal Olmayan İndeks
OÖB	: Orta Öncelikli Binalar
PCA	: Temel Bileşen Analizi
PERA	: Hızlı Performans Değerlendirme Yöntemi
PP	: Performans Puanı
PS	: Performans Puanı
RCNN	: Hızlı Tekrarlı Konvolüsyonel Sinir Ağı
RVS	: Hızlı Görsel Tarama
RYTEİE	: Riskli Yapıların Tespit Edilmesine İlişkin Esaslar
SI	: Yapısal İndeks
SPI	: Sismik Öncelik İndeksi
SVM	: Destek Vektör Makineleri
TBDY	: Türkiye Bina Deprem Yönetmeliği
TP	: Taban Puan
VS	: Güvenlik Puanı
YDG	: Yeterli Deprem Güvenliği
YÖB	: Yüksek Öncelikli Binalar
YSA	: Yapay Sinir Ağları
YSP	: Yapısal Taşıyıcı Sistem Puanı

1. GİRİŞ

Dünyanın en önemli deprem kuşaklarından birisi üzerinde bulunan Türkiye’de birçok etkili ve yıkıcı depremler meydana gelmiştir. Türkiye’de yürürlükte olan ve yaklaşık son yirmi yıl içinde (1998, 2007 ve 2018) üç kez kapsamlı değişikliğe uğrayan deprem yönetmelikleri oldukça katı kurallar içerse de ne yazık ki yapılarda büyük yıkımlar ve can kayıpları oluşmaktadır. Büyük yıkımların birincil nedeni, özellikle 1998 ve öncesinde çeşitli nedenlerle mühendislik hizmeti almamış, malzeme yönünden yetersiz ve yapım tekniği açısından güvensiz yapı sayısının oldukça fazla olmasıdır. Ülkemizde betonarme ve yığma binaların yapı stokunun %90’ını oluşturması ve bu binaların yaklaşık %30-%45’lik kısmının 1998 ve öncesinde inşa edilmiş olması da bu durumu açıklamaktadır. Ayrıca yapıların önemli kısmının aktif fay hatları üzerinde veya fay hatlarına yakın lokasyonlarda bulunması olası bir deprem sonrasında ağır hasar göreceği ya da tamamen yıkılacak riskli bina sayısının fazlaca olmasına neden olmaktadır. Bununla beraber, binaların önemli kısmının 3-8 kat arasında konut türü binalar olması can kayıplarının artmasına da neden olmaktadır.

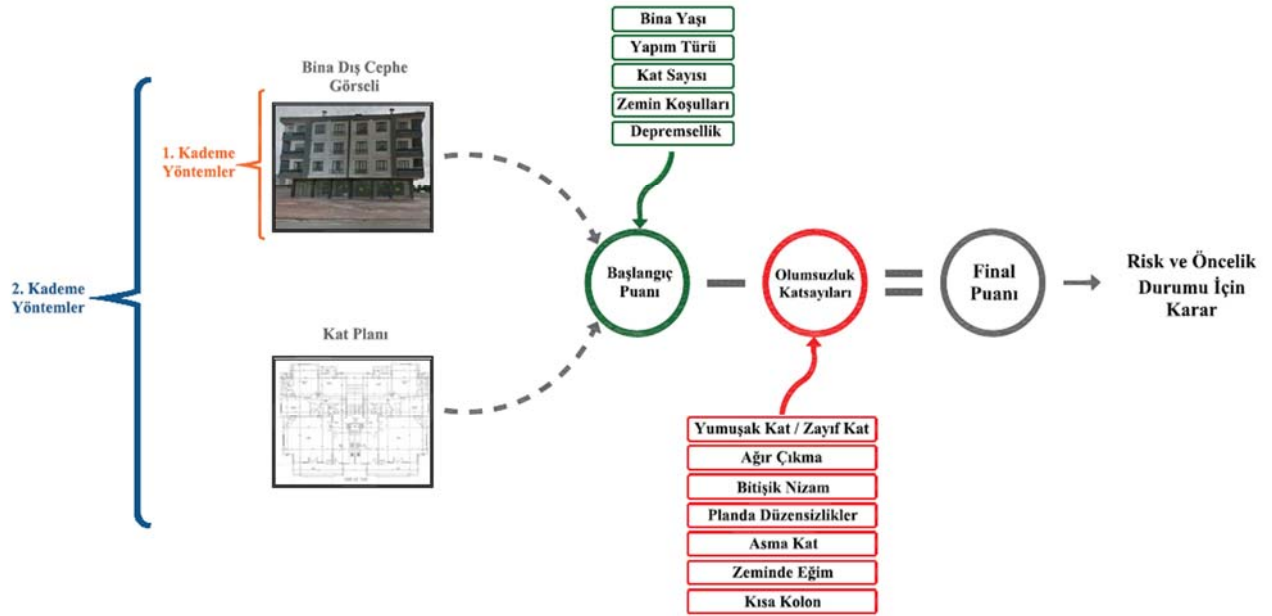
Bu sebeple meydana gelebilecek şiddetli depremlerde olası yıkımların ve can kayıplarının önlenmesi için; deprem açısından riskli binaların hızlı bir şekilde tespit edilmesi ve acil müdahale gerektiren yapılardan başlanılarak depreme hazır hale getirilmesi son derece önemli ve gereklidir. Ancak ekonomik kaynakların yetersizliği, zaman ve yapı stokunun büyüklüğü düşünüldüğünde, yapıların deprem risk analizlerinin güncel deprem yönetmeliğinde (Türkiye Bina Deprem Yönetmeliği (TBDY-2018)) belirtildiği şekliyle detaylı saha incelemeleri gerektiren yöntemler ile hızlı, kapsayıcı ve ayrıntılı bir şekilde gerçekleştirilmesi oldukça güçtür.

Sonuç olarak zaman ve ekonomik faktörler baz alındığında binaların tamamı için detaylı bir analiz yapılamayacağından sadece risk açısından öncelikli olan yapıların hızlı değerlendirme metodları ile tespit edilerek sonrasında bu yapılar için TBDY-2018’de belirtildiği şekliyle detaylı performans analizi yapılması yeterli olacaktır. Bu nedenle depreme maruz kalmadan önce hızlı ve etkin şekilde yapıların riskli olanlarının öncelik sırası belirlenerek acil müdahale gerektiren yapılardan başlanılarak depreme hazır hale getirilmesi oldukça önemlidir.

Literatürde, mevcut binaların risk durumlarını belirleyen hızlı sismik değerlendirme yöntemleri geliştirilmiştir. Hızlı değerlendirme yöntemlerinden beklenen, binaların depreme dayanıklı olup olmadığını kesin olarak sınıflandırmak değildir. Hızlı sismik değerlendirme yöntemlerinde (deprem risk analizi) önemli olan binaların mevcut hali ile depreme dayanıklılık durumunun mümkün olduğunca kesin ve hızlı bir şekilde (kısa sürede) belirlenmesi ve deprem öncelik durumlarına göre gruplandırılmasıdır.

Hızlı değerlendirme yöntemleri deprem yönetmeliklerinde (örneğin TBDY-2018 gibi) tanımlanan detaylı ve karmaşık hesap prosedürünü ve modelleme aşamalarını içermemektedir. Bu tür hızlı değerlendirme yöntemlerinin tümünde; binaların mevcut deprem performansına etki eden, kat

sayısı, bina yüksekliği, planda ve düşeyde düzensizliklerin varlığı, binanın yapım yılı, binanın bulunduğu bölgenin depremselliği, binanın yapım türü, binanın oturduğu zemin koşulları, binalarda çıkma kat bulunup bulunmaması, bitişik nizam yapılardaki olası çarpışma etkisi gibi parametreler bulunmaktadır. Ayrıca yöntemlerin bazılarında bu parametrelere ilave olarak zemin katta (kritik katta) kolon ve perde kesit alanları ve doğrultuları, zemin katta dolgu duvarların olup olmaması (ticari amaçla kullanılma durumu) vb. parametrelere bağlı olarak binaların risk durumlarına yönelik sayısal ifadeler yer almaktadır. Yöntemlerin genelinde binaların yaşına, kat sayısına, yapım türüne, zemin koşullarına göre verilen başlangıç skor puanından, yapısal kusurlardan elde edilen negatif puanlar çıkartılarak binalar için nihai bir skor tespit edilir. Nihai skora göre envanter içindeki yapılar gruplandırılarak deprem açısından müdahale önceliği olan binalar tespit edilir. Elde edilen sayısal veriler literatürde bulunan yöntemler için belirlenen puanla karşılaştırılarak binanın detaylı analiz açısından önceliği belirlenir. Şekil 1.1’de literatürde yer alan hızlı sismik değerlendirme yöntemlerinin genel olarak izlediği akış şeması gösterilmiştir.



Şekil 1.1. Geleneksel yöntemlerde hızlı değerlendirme akış şeması

Hızlı değerlendirme yöntemleri 2000’li yılların başında Amerika Birleşik Devletleri’nde FEMA-154 (ATC 1988) ile Japonya’da ise Japon Sismik İndeks Yöntemi (1990) ile başlamıştır. Bu konuda yapılan ilk çalışmaların başında da Hassan ve Sözen’in (1997) 1992 yılında Erzincan’da yaşanan depremde hasar gören 46 binanın verilerini kullandıkları çalışma gelmektedir. Binaların deprem öncesi hızlı değerlendirmesine yönelik özellikle Türkiye’de pek çok araştırmacı tarafından önerilen farklı çalışmalar vardır. Literatürde yer alan hızlı değerlendirme yöntemleri genellikle iki gruba ayrılır:

1. kademe yöntemler: genellikle binanın dış cephe görseli (cadde fotoğrafı ya da street view) ile bölgeye ait diğer depremsellik parametreleri kullanılan hızlı değerlendirme yöntemleridir. FEMA-154 (1998), Japon Sismik İndex (1990), Sucuoğlu ve ark. (2007), RYTEİE-2019 (2019) görsele dayalı 1. kademe yöntemlerden bazılarıdır.

2. kademe yöntemler: yapının dış cephe görseli yanında kritik katında (daha çok zemin kat olarak kabul edilir) taşıyıcı sistem elemanlarının yerleşimi, boyutları ve türlerine göre belirlenen bina kapasitesinden yola çıkarak değerlendirme yapan kapasiteye dayalı hızlı değerlendirme yöntemleridir. P25 (2005), Yakut (2005), Anadolu Üniversitesi Hızlı Değerlendirme Yöntemi AURAP (2017), DURTES (2003) ve PERA (2014) gibi yöntemler ise hem cephe görseli hem de plan bilgilerinin kullanıldığı kapasiteye dayalı 2. kademe yöntemlerdendir.

1. kademe yöntemlerden; Sucuoğlu ve ark. (2007), tarafından yapılan çalışmada orta yükseklikteki mevcut betonarme binalar için bir risk değerlendirme yöntemi geliştirilmiştir. Geliştirilen yöntemde binalar için sokaktan gözlenebilen bina parametrelerini kullanarak bir risk sıralaması yapılmaktadır. Sucuoğlu ve ark. (2007)'nin önerdiği yönteme benzer içeriğe sahip olan ve Türkiye'de mevcut betonarme bina stokunun hızlı ve ekonomik şekilde değerlendirilmesi amacıyla Çevre ve Şehircilik Bakanlığı tarafından yayımlanan RYTEİE-2019 da yine bir risk öncelik sıralaması yapılmaktadır. Tüm binalar için uygulanabilen FEMA-154 yöntemi de görsele dayalı hesap prosedürünü içermektedir. FEMA-154 birçok ülkede de farklı şekillerde kullanılmaktadır (Karbassi ve Nollet (2007), Wallace ve Miller (2008), Srikanth ve ark. (2010), Saatcioglu ve ark. (2013), Perrone ve ark. (2015), Ploeger ve ark. (2016), Ningthoujam ve Nanda, (2018)).

2. kademe yöntemlerden; Yakut (2004) tarafından sunulan yöntemde, mevcut betonarme binaların olası deprem performansını hızlı değerlendirmek için Kapasite İndeksi parametresi hesaplanmaktadır. Bu yöntem, binaları güvenli olup ciddi hasar almamış ya da güvenli olmayıp hedef performans düzeyi karşılanmamış olarak sınıflandırmaktadır. P5 Yöntemi Tezcan ve ark. (2002 ve 2003) tarafından mevcut binaların hızlı bir şekilde değerlendirilmesi için önerilmiş yöntemlerden bir tanesidir. Tezcan ve ark. (2005) P5 Yöntemini geliştirerek P24 Yöntemini önermiştir. P24 Yöntemi çok sayıda binaya uygulanarak kalibre edilmiş ve yeniden düzenlenerek Bal ve ark. (2007) tarafından P25 Yöntemi olarak ifade edilmiştir. Gülay ve ark. (2008) P25 Puanlama Yönteminin kalibrasyonunu yapmış ve 1998 yılından önce yapılmış mevcut betonarme binaların ön değerlendirilmesi P25 Yöntemi ile yapılarak riskli binaların hızlı şekilde belirlenmesi sağlanmıştır. Kaplan ve ark. (2017), Yakut (2004)'a benzer bir yaklaşımla konut tipi betonarme binalar için Anadolu Üniversitesi Hızlı Değerlendirme Yöntemi (AURAP) adıyla bir yöntem geliştirmiştir. Kaya (2017) P25 Hızlı Değerlendirme Yöntemi üzerinden görel kat öteleme değerlerinin de sonuç puanına etkimesini de düşünerek P25-V. ÖZKA yöntemini geliştirmiştir. İlki ve ark. (2014) da PERA isminde özellikle eleman kapasitesi üzerinden bir değerlendirme sistemi geliştirmişlerdir.

Bu yöntemlerin tamamı literatürde kabul görmüş, geçmiş depremlerden elde edilen verilere göre binaların hasar/yıkılma ihtimalinin tahmin başarısı, kullanılabilirlik, hesap prosedürünün zorluğu vs. parametreleri açısından çok sayıda araştırmacı tarafından karşılaştırılmıştır. Örneğin Arslan (2017), Çıracak (2016) ve Özkaratay (2014), mevcut betonarme konut binalarının Japon Sismik İndeks Yöntemi, P25 Puanlama Yöntemi ve Yakut Yöntemi ile elde ettiği sonuçları DBYBHY-2007 sonuçları ile karşılaştırmıştır. Kızılkaya (2018), üç farklı bloktan oluşan bir ilkokul binası üzerinde FEMA-154 ve Kanada Sismik Tarama Yönteminin daha hızlı uygulanabilir yöntemler olduğunu Japon Sismik İndeks Yönteminin ise uygulaması daha çok zaman alan ancak daha güvenilir sonuçlar veren bir yöntem olduğu sonucuna ulaşmıştır. Özkaynak ve Özbay (2018), İstanbul'da bulunan orta yükseklikteki betonarme binaların deprem güvenliğini Hızlı Görsel Tarama (Rapid Visual Screening-RVS) Yöntemini kullanarak belirlemişlerdir. İslam ve ark. (2019), tarafından yapılan çalışmada, deprem güvenliği bulunmayan binaları tanımlamak için görsel değerlendirme yöntemi sunulmuştur. Murashko ve İlham (2017), Ghafar ve ark. (2014) ve Modi ve Mohan (2019) çalışmalarında RVS yöntemini diğer yöntemlerle karşılaştırmıştır. Kömür ve ark. (2007), Çelik ve ark. (2007), Ersin ve Boduroğlu (2010), Baran ve ark. (2011), Özhendekçi ve Özhendekçi (2012), Işık ve Kutanis (2013), Doğan ve ark. (2021), Erdil ve Ceylan (2019) yine literatürde mevcut yöntemleri kullanarak hızlı değerlendirme yöntemleri ile farklı karşılaştırmalar yapmışlardır. Aldemir ve ark. (2020) yığma, Işık ve ark. (2013) ile Çoşkun ve ark. (2019) ise betonarme binalar için yeni hızlı değerlendirme metotları sunmuşlardır.

Yukarıda özetlenen literatürden de anlaşılacağı üzere Türkiye'de betonarme ve yığma binaların sismik açıdan hızlı değerlendirilmesi oldukça önemli ve popüler bir konudur. Bununla beraber deprem öncesi hızlı değerlendirmeler ile ilgili son yıllarda saha çalışmaları ve analitik verilere dayalı yapay zekâ yöntemleri/akıllı yazılımlar da kullanılmaya başlanmıştır. Günümüzde çoğu karmaşık mühendislik problemlerinin çözümünde akıllı yazılımlar (yapay zekâ, genetik algoritma, bulanık mantık vb.) kullanılmaktadır. Bu yazılımlar yüksek doğruluk oranları ile sonucu öngörebildikleri, maliyetten tasarruf ve zaman kaybı açısından önemli avantajlar sağladıkları için tercih edilmektedirler. 1950'li yıllarda başlayan Yapay Zekâ (Artificial Intelligence-AI) kullanımı, gelişen bilgisayar bilimi sayesinde 1980'li yıllarda Makine Öğrenmesinin (MÖ) (Machine Learning), 2010'lu yıllarda Derin Öğrenmenin (Deep Learning-DÖ) ve özellikle son beş yıldır da Evrişimli Sinir Ağları (Convolutional Neural Networks-CNN) yöntemlerinin oldukça popüler olarak kullanılmasına neden olmuştur.

Diğer taraftan, deprem öncesi mevcut binaların hızlı sismik risk analizi için şehir merkezlerinde incelenecek yapılar yüz binlerle ifade edilebilir. Yapıların deprem risk öncelik sırasının belirlenmesi, envanterin çok fazla olmasından dolayı çok büyük bir bütçe ve zaman gerektirmektedir. Sayının çok fazla olması çok sayıda uzman görevlendirilmesine sebep olacaktır. Deprem risk analizinin çok sayıda farklı parametreye bağlı olması sebebiyle karmaşık mühendislik

problemlerinin çözümünde de kullanılan akıllı sistemlerden faydalanılacaktır. Özellikle verilen kararların mümkün olduğunca standart, hızlı ve ölçülebilir şekilde alınması ekonomik fayda sağlayacaktır.

Literatürde deprem öncesi riskli yapı analizi ve gruplandırmaya yönelik yapılan çalışmalarda; Arslan ve ark. (2011) ve Garip (2012), tarafından betonarme binaların hızlı performans tahmini için Yapay Sinir Ağları (YSA) kullanılmıştır. Arslan (2009, 2010) mevcut betonarme binaların deprem performansına etki eden parametrelere yönelik YSA'yı, Kumar ve ark. (2017) RVS metodunu, Dristos ve Moseley (2013) bulanık mantık metodunu kullanmışlardır. Morfidis ve Kostinakis (2018)'de deprem sonrası hasar kayıtlarını YSA'da eğiterek mevcut binalar için hasar tahmininde bulunmuştur. Harirchian ve Lahmer (2020), betonarme binaların depreme karşı dayanıklılığını etkileyen geometrik özellikleri (kat adedi, kolon alanı, toplam zemin alanı vb.) dikkate alarak Arslan (2009, 2010) gibi YSA vasıtasıyla betonarme binaların hasar seviyesini tahmin etmişlerdir. Harirchian ve ark. (2020a ve 2020b), mevcut binaların deprem tehlikesinin hızlı değerlendirilmesi için MÖ yöntemi olan Destek Vektör Makineleri (Support Vector Machine-SVM) modelini ve YSA'yı kullanmışlardır. Perrone ve ark. (2015) hastane binaları için bir Güvenlik İndeksi belirlemek amacıyla hızlı bir görsel tarama ile RVS Yöntemini önermişlerdir. Zhang ve ark. (2019) bir veri madenciliği tekniği geliştirerek bölgesel ölçekte binaların sismik hassasiyetini değerlendirmek için SVM kullanmıştır. Bu çalışmalarda temel amaç yapının deprem performansına etki eden parametrelerle sonuç puanı arasında bir ilişki kurarak sistemi eğitmek ve test edilmemiş farklı binalar üzerinden eğitilen sistemin doğruluğunu sınavarak yöntemin başarısını ortaya koymak olmuştur. DÖ ve CNN'nin oldukça yeni ve popüler bir konu olması nedeniyle bu konuda söz konusu yöntemlerin kullanıldığı kapsamlı bir çalışma literatürde bulunmamaktadır.

CNN genellikle görüntü işleme alanında kullanılan ve girdi olarak görselleri kullanan bir DÖ algoritmasıdır. Farklı operasyonlarla söz konusu görsellerdeki özellikleri (feature) yakalayan ve onları sınıflandıran bu algoritma, klasik MÖ algoritmalarına kıyasla veri ön işleme açısından oldukça hızlıdır. Bu algoritma ile ilgili olarak sürekli ilerlemeler ve gelişmeler kaydedilmektedir. Güncel literatürde çok fazla bilinen bazı Ön Eğitilmiş CNN mimarileri: LeNet, AlexNet, VGGNet, GoogLeNet, ResNet, ZFNet, ShuffleNet, Xception, SqueezeNet, Inception ResNet, NasNet Large, EfficientNet vb. olarak sınıflandırılabilir. Literatürde son yıllarda bu algoritmalar kullanılarak inşaat mühendisliği alanında birçok çalışma icra edilmiştir. Yu ve ark. (2020 ve 2021) binalardaki yumuşak kat oluşumunu sokak taraması yöntemiyle elde ettikleri görseller üzerinden DÖ sınıflandırması kullanarak tespit etmişlerdir. Kang ve ark. (2018) tarafından yapılan çalışmada, binaların işlevselliğini sınıflandırmak için (ofis binası, kilise, konut, garaj, endüstri yapısı vb.) Ön Eğitilmiş KSA yapıları kullanılarak genel bir çerçeve önerilmiştir. Gültekin (2022) tarafından yapılan yüksek lisans tezinde ise VGG-19 mimarisi kullanılmak suretiyle betonarme yapılarda yapısal ve yapısal olmayan hasarlar tespit edilmiştir. Yapı teknolojisinde; nesne algılamaya, görüntü

işleme/ayırmaya ve elde edilen verileri sınıflandırmaya yönelik farklı çalışmalar da bulunmaktadır. Bu çalışmalardan bir kısmı: Doğan ve ark. (2020), Bal ve ark. (2021), Perez ve ark. (2019), Nahata ve ark. (2018), Şengezer ve ark. (2008), Rezai ve ark. (2020), Valentijn ve ark. (2020), Kim ve ark. (2020), Ali ve ark. (2018), Griffiths ve ark. (2018), Choi ve ark. (2008), Arif ve ark. (2013), Metin ve ark. (2020), Lei ve ark. (2018), Malesa ve ark. (2010), Yoshitake ve ark. (2018), Lee ve ark. (2004), Oskouie ve ark. (2015), Liebold ve ark. (2016), Dao ve ark. (2020), Teizer ve ark. (2007), Karaaslan ve ark. (2018), Mohamad ve ark. (2019), Kim ve ark. (2020), Zhank ve ark. (2019), Zhu ve ark. (2010), Perez ve ark. (2019), Vashpanov ve ark. (2019), Maalek ve ark. (2015), Ming ve ark. (2021)) tarafından yapılmıştır.

Hızlı değerlendirme işlemlerinin özellikle deprem mühendisliğinde uzman bir inşaat mühendisi tarafından yapılması oldukça önemlidir. Uzman mühendisin binanın projesi ve bina cephe görseli üzerinden yapacağı değerlendirmeler Şekil 1.1’de gösterilen haliyle başlangıç puanına ve olumsuzluk puanına etki edeceği için sonuç skorunun belirlenmesinde oldukça önem arz etmektedir.

Hızlı değerlendirme yöntemlerinin parametrelerinin akıllı sistemlerle (YSA, CNN, DÖ, MÖ) tespitine yönelik literatürde çok sayıda çalışma bulunmamaktadır. Sadece Yu ve ark. (2020) tarafından yapılan çalışmada bina geometrik özelliklerinden yumuşak kat varlığı DÖ modeli kullanılarak tespit edilmeye çalışılmıştır. Bu bağlamda Hızlı değerlendirme parametrelerinin bu yöntemlerle araştırılması son derece önemli ve üzerinde detaylı çalışmalar yapılmamış bir konu olarak görülmektedir.

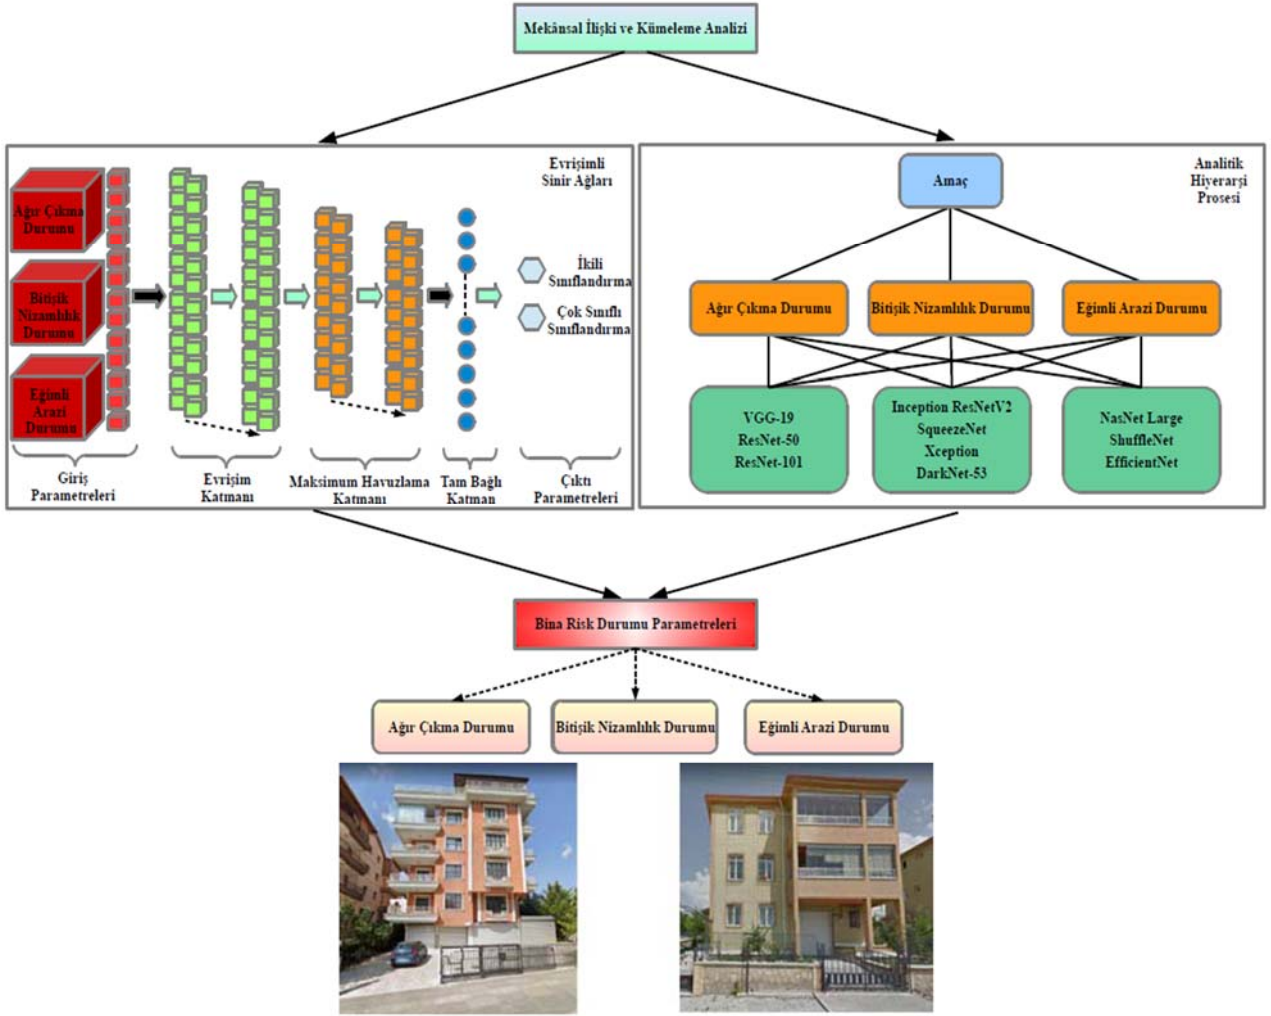
Bu tez kapsamında; konut türü betonarme binaların deprem öncesi risk analizinde uzman mühendise yardımcı olacak (ya da teknik uzman yokluğunda karar vermeyi kolaylaştıracak) ve risk önceliklendirilmesinde (hızlı sismik değerlendirme metodlarında) kullanılacak parametrelerden olan ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi varlığı durumlarını bina cephe görselleri üzerinden elde edebilen, Ön Eğitilmiş Evrişimli (Konvolüsyonel) Sinir Ağları (CNN) yapıları kullanılarak (DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50) söz konusu DÖ modelleri mukayese edilmiş ve sonuçlar detaylı olarak irdelenmiştir. Ayrıca, bahse konu parametreler (ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi varlığı durumu) ikili sınıflandırma (binary classification) ve çok sınıflı sınıflandırma (multi class classification) algoritmaları kullanılmak suretiyle 4 farklı veri seti üzerinden MATLAB programı aracılığıyla eğitime tabi tutulmuş ve bu parametrelerin doğruluk yüzdeleri test edilmiştir.

Bu tez çalışması aslında Şekil 1.1’de verilen bir betonarme binaya ait geleneksel yöntemlerde hızlı sismik değerlendirmeye ilişkin tüm geometrik parametrelerin belirlendiği bir projenin parçası olarak (Arslan ve ark. (2021) tarafından patent başvurusu yapılmış olan ‘‘Konut Türü Binaların Deprem Risk Önceliklerinin Tespitinde Kullanılan Geometrik Parametrelerin Evrişimli Sinir Ağları ile Belirlenmesi Yöntemi’’ adlı çalışma) yukarıda ifade edildiği üzere ağır çıkma, bitişik nizamlılık

durumu ve eğimli arazi varlığı durumlarının Ön Eğitimli Evrişimli (Konvolüsyonel) Sinir Ağları (CNN) yapılarının kullanılması suretiyle tespit edilmesi işlemlerini kapsamaktadır. Ayrıca, bu tez çalışması ile paralel olarak devam eden ve yeni araştırmacılarla yapılacak diğer tez çalışmalarında bahse konu parametrelerin (bina yüksekliği, kısa kolon varlığı, yumuşak kat/zayıf kat varlığı, kolon-perde-duvar yerleri ve alanlarının tespiti, döşeme boşluk miktarının tespiti, planda çıkıntı olması durumu, planda aksların paralel olmaması durumu vb.) bir veya birkaçı tespit edilerek hızlı sismik değerlendirme yöntemlerinde gereklilik arz eden tüm parametrelerin belirlenmesi işlemleri tamamlanmış olacaktır.

Diğer taraftan, veri setlerinin elde edilmesi için Google Street View Static API (Google, 2007) kullanılmış ve 4500 adet nitelikli cephe görseli toplanmış ve eksik kalan bazı veriler gerekli veri dengeleme işlemlerine tabi tutularak (noise, mirror vb.) çoğaltılmıştır.

Gerçekleştirilen tez çalışması toplamda 7 bölümden oluşmaktadır. Tezin birinci bölümü giriş kısmı olup ikinci bölümde kaynak araştırması adı altında hızlı sismik değerlendirme yöntemleri ve söz konusu yöntemleri DÖ modelleri ile entegre olarak kullanan çalışmalar sunulmuştur. Üçüncü bölümde yaygın deprem hasarları ve deprem öncesi hızlı sismik değerlendirme yöntemlerinden bahsedilmiş, dördüncü bölümde ise yapay zekânın tanımı ve tarihsel gelişimi konuları ele alınmıştır. Beşinci bölümde tez kapsamında kullanılan materyal ve yöntemden bahsedilmiştir. Altıncı bölümde ise gerçekleştirilen çalışmalar ve elde edilen bulgular anlatılmıştır. Yedinci bölüm, son bölüm olup sonuçlar ve öneriler kısmından oluşmaktadır. Çalışmanın temel işleyişi Şekil 1.2'deki özette (Graphical Abstract) görülmektedir.



Şekil 1.2. Tez çalışması genel akış şeması

2. KAYNAK ARAŞTIRMASI

2.1. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemlerine İlişkin Kaynak Araştırması

Şu ana kadar, mevcut yapıların davranışlarının olabildiğince çabuk ve pratik bir biçimde ele alınabilmesi için birçok hızlı değerlendirme yöntemi ortaya atılmıştır. Bu çerçevede icra edilen ilk uygulamalar Amerika Birleşik Devletleri'nde, mevcut yapıların deprem performanslarının saptanması gayesi doğrultusunda "Applied Technology Council (ATC)" tarafından yayımlanan ATC 21 ve ATC21-1, ATC 40 ve "Federal Acil Durum Yönetim Kurumu (FEMA)" tarafından yayımlanan FEMA-273, FEMA-356, FEMA-440 yönetmelikleridir. Söz konusu yönetmelikler yapıların depreme karşı dayanıklılıklarının tayin edilmesi ve davranışlarının daha realize edilmesine yönelik dikkat çekici uygulamalardır. Bu yönetmeliklerin usul ve yöntemleri yeterince kapsamlı bir biçimde ortaya konulan ATC 40 ve FEMA-440 vasıtası ile icra edilen analiz prosedürlerini bünyesinde barındırmaktadırlar.

Daha spesifik olarak ifade etmek gerekirse hızlı değerlendirme yöntemlerinin deprem mühendisliği disiplininde önemli bir şekilde yer almasını sağlayan ciddi ilerlemelerden biri Amerika Birleşik Devletleri'nde ATC 21 ve ATC 21-1 yönetmelikleridir. Bu yönetmelikler, 1988 yılında ATC vasıtasıyla tanzim edilmiş ve FEMA aracılığıyla uygulamaya konu olarak 2002 yılında da revize edilmiştir. Söz konusu yöntem ile hâlihazırdaki yapılar detaylı olarak incelenmeden sokak taraması olarak ifade edilen ve yapıların dış özelliklerinin gözlemlenerek değerlendirilmesi neticesinde elde edilen risk puanının belirlenmesi hedeflenmektedir. FEMA-154'te yöntemle ilişkin değerlendirme kıstasları açıklanırken FEMA-155'te ilave doneler sunulmaktadır. FEMA-154'te ilk olarak binalar taşıyıcı sistem özellikleri ve malzeme muhteviyatlarına göre 13 farklı sınıfa ayrılmakta (yığma, betonarme, prefabrik vb.) ve bu kategorizasyon uyarınca yapılara bir başlangıç puanı verilmektedir. Bahse konu yapıların incelenmesi neticesinde erişilen menfi ve müspet parametre puanları vasıtasıyla esas puan olarak ifade edilen S puanı belirlenmektedir. FEMA-154, oluşabilecek bir afet halinde alanlarda ortaya çıkabilecek zararları belirlemeyi ve afet yönetiminde mevcut binalar için gerekli alt yapıyı teşkil etmeyi hedeflemektedir. Ayrıca söz konusu metottan elde edilen doneler bu doğrultuda FEMA vasıtasıyla geliştirilen afet koordinasyonu ve risk bazlı zarar analizi yazılımı HAZUS'ta (Ulusal Deprem Tehlikelerini Azaltma Programı) kullanılmaktadır.

Hızlı değerlendirme yöntemlerinin öncü çalışmalarından biri de Japonya'da 1968 yılında Tokachioki'de yaşanan depremin akabinde uygulamaya konulmuştur. Yaşanan deprem neticesinde birçok betonarme bina büyük oranda hasar görmüştür. Shiga, Shibata ve Takahashi 1968 yılında icra ettikleri çalışmada, söz konusu depremde elde edilen doneleri dikkate alarak kolon-duvar indeksini baz alan SST isimli bir hızlı değerlendirme metodu geliştirmişlerdir. Geliştirilen bu yöntem 1975'te Japonya Mimari Enstitüsü (AIJ) tarafından "Seismic Capacity Evaluation Method for R/C School

Building” adlı çalışmada sınıanmış ve neticeleri sunulmuştur. Sismik İndeks olarak isimlendirilen söz konusu hızlı değerlendirme metodu 1977 yılında Japonya Bina Afet Önleme Kurumu (JBDPA) tarafından “Standart for Seismic Safety Evaluation and Guideline for Retrofitting of Existing R/C Buildings” adlı yönetmelik olarak tanzim edilmiştir. 1977’de JBDPA aracılığıyla yayımlanan standart 1990’da Tokyo Üniversitesi Endüstriyel Bilimler Kurumuna başkanlık yapan Prof. Dr. T. Okada tarafından yeniden düzenlenmiştir. 2001 yılında revize edilmek suretiyle söz konusu standardın ilk İngilizce yayını gerçekleştirilmiştir. Japon sismik indeks yöntemi mevcut binaların depreme karşı mukavemetini saptamak amacıyla kullanılan 3 kademeli bir prosedür dahilinde olup metodun esası eşit enerji ilkesine mesnetlendirilmiştir.

Hassan ve Sözen (1997) tarafından yapılan çalışmada, 1992 yılında Erzincan ilinde yaşanan deprem neticesinde hasara uğrayan 46 binanın dataları dikkate alınmıştır. Bu datalar Orta Doğu Teknik Üniversitesi teknik uzmanlarından müteşekkil bir ekibin çalışmaları neticesinde ortaya konulmuştur. Bahse konu binaların tümünün kat yükseklikleri 2,75-3,60m arasında ve toplam kat sayıları ise 1-5 aralığındadır. Tamamen göçme durumu yaşanmayan bahse konu 46 binaya uygulanan metotta yalnızca duvar ve kolon kesit alanları dikkate alınmıştır. Yapılan çalışmanın neticesinde binaların 4 farklı kategorizasyon (toptan göçme, ağır hasar, orta hasar, hafif hasar) dahilinde sınıflandırılabilmesi amacıyla duvar ve kolon kesit alanları için sınır indeks değerleri tayin edilmiştir.

Keleşoğlu ve ark. (2002) tarafından İstanbul ili Bakırköy ilçesinde risk analizi uygulaması icra edilmiştir. Yapılan çalışma iki merhaleden oluşmaktadır. Birinci merhalede, 125 sismik kırılma deneyi, 87 adet sondaj uygulaması, 210 elektrik resistivite deneyi yapılarak neticelerinden faydalanmak suretiyle bölgenin sismisitesi, jeolojik yapısı ve geoteknik özellikleri değerlendirilerek mikro bölgeleme işlemi tesis edilmiştir. Söz konusu uygulama sonucunda tespit edilen zemin özelliklerine ilişkin parametreler Durtes hızlı değerlendirme programı için zemin değişkenleri olarak kullanılmıştır. İkinci merhalede ise Durtes yazılımına, dikkate alınan binalara ilişkin bilgiler aktarılmıştır. Söz konusu yazılım programında; binanın yaşı, taşıyıcı sistem türü, kat sayısı ve yükseklikleri, bina düzensizlikleri, malzeme karakteristikleri (beton ve donatı) vb. yüz civarı parametre dikkate alınmıştır. İcra edilen uygulama neticesinde Bakırköy ilçesinde takribi 10.500 binada risk durumu tespiti yapılmıştır. Yönetmeliklerde yer alan kesin değerlendirme metotları ile mukayeseler yapılmış ve yapılan çalışmada elde edilen neticeler ile kesin değerlendirme metotları neticelerinin büyük oranda uyumlu olduğu tespit edilmiştir.

Öztorun ve Temur (2002), yapıların depreme karşı hassasiyetlerinin tespiti amacıyla geliştirilmiş olan Durtes yazılım programı neticelerinin sonlu elemanlar metotlarının kullanıldığı yazılım programları sonuçları ile mukayese edilmesine ilişkin bir çalışma yapmışlardır. Söz konusu çalışma dahilinde 7 katlı betonarme bir bina dikkate alınmıştır. Durtes yazılım programı ile sonlu elemanlar metotlarının kullanıldığı yazılım programlarının akreditasyonları sağlanmıştır.

Oluşturulması uzun süreler alan bir modelin söz konusu yazılım programı ile çok kısa sürede teşkil edilerek yüksek doğruluklu sonuçlara erişildiği görülmüştür.

Tezcan ve ark. (2002, 2003) yaşanabilecek olası bir depremde can kayıplarının minimize edilmesi amacıyla kısa sürede ve düşük maliyetle tüm binalara ilişkin risk analizlerinin icra edilmesine ihtiyaç olmadan doğru sonuçlar elde edebilen P5 Metodu ve Sıfır Can Kaybı yaklaşımı olarak bilinen hızlı değerlendirme yöntemlerinin geliştirilmesini hedeflemişlerdir. Söz konusu yaklaşımda ilk olarak riskin fazla olduğu binaların analizlerinin yapılmasını diğer binalara ilişkin olarak da çeşitli inisiyatiflerin alınması gerektiğini öne sürmüşlerdir. %96'sı güvenlik açısından zaafiyet arz eden İstanbul'daki binaların tümünün yerine, "1999 Kocaeli ve Düzce depremlerinde konut ve işyeri özelinde toplam 854.000 binanın yalnızca %6'sı ağır hasarlı ve yıkıktır" istatistiki verisinden hareketle olası bir depremde can kayıplarının engellenmesi için bahse konu binaların %6'sının önceden saptanarak detaylı incelenmesinin daha basit ve çabuk olduğu dile getirilmiştir.

Boduroğlu ve ark. (2004) tarafından yapılan çalışmada, İstanbul ve İzmit illerinde yer alan 5 adet bina dikkate alınmak suretiyle Japon Sismik İndeks Yönteminin birinci kademesi uygulanmıştır. Söz konusu binaların halihazırdaki durumları ile güçlendirilmiş durumları için Japon Sismik İndeks Yöntemi ve ABYYHY-1998 kriterleri uyarınca analizler yapılarak deprem performansları tayin edilmiştir. ABYYHY-1998'de elastik yöntemin baz alındığı değerlendirme için SAP2000 programı kullanılmıştır. Analiz neticesinde tasarım momentleri (M_d) ve dizayn kesme kuvvetleri (V_d) hesaplanmıştır. Kesme kuvveti kapasiteleri (V_r) ve Moment kapasiteleri (M_r) TS 500'deki taşıma kapasitesi kriterleri uyarınca hesaplanmıştır. Japon Sismik İndeks Yöntemine göre icra edilen analiz neticesinde her bir yapının "yapısal sismik performans indeksi" (I_s) ve "karşılaştırma indeksi" (I_{so}) katsayıları belirlenmiştir. Bahse konu indekslerin hesaplanmasında bina geometrisi, düşeyde ve plandaki düzensizlikler, zemin özellikleri, bina kullanımına ilişkin detaylar, bina yaşı, binadaki deformasyonlar, binanın önceden geçirmiş olduğu yangın deneyimi gibi birçok karakteristik özellik dikkate alınmıştır. Bahse konu binaların güçlendirilmiş ve güçlendirilmemiş durumlarının her bir katındaki $\Sigma M_r / \Sigma M_d$ ve $\Sigma V_r / \Sigma V_d$ değerleri hesaplanmıştır. Bu değerlerin 1'den büyük olması durumunda binanın güvenli olduğu anlamı çıkarılmaktadır. Benzer şekilde I_s / I_{so} değerleri de her bir bina ve her bir kat özelinde hesaplanmıştır. Kesme kuvveti ve moment kapasite değerlerinde olduğu gibi, bu değerlerin de 1'den büyük olması binanın güvenli olduğu anlamına gelmektedir. Çalışma neticesinde elde edilen bu üç değer birbirlerine göre paralellik arz eden değişimi, ABYYHY-1998 kriterleri uyarınca icra edilen deprem performansı değerlendirmesi ile Japon Sismik İndeks Yönteminin birbirleri ile tutarlı sonuçlar verdiğini göstermiştir.

İnel ve ark. (2004) tarafından yapılan çalışmada Denizli ilinde yer alan kamuya ait 9 binanın risk değerlendirilmesi yapılmıştır. Söz konusu binalar doğrusal olmayan itme analizi (pushover) baz alınmak suretiyle SAP2000 programı vasıtasıyla değerlendirmeye tabi tutulmuştur. Bahse konu analiz işlemlerinde Pamukkale Üniversitesince detaylı olarak incelemeye tabi tutulan kamuya ait

binalardan elde edilen karot dayanımları ve düşey taşıyıcı elemanlardaki etriye özellikleri dikkate alınmıştır. Pushover analizi yapılması amacıyla teşkil edilen modellerde DBYBHY-2007, FEMA-356 ve ATC-40 yönetmelikleri kullanılmıştır. Yapılan çalışma neticesinde ciddi bulgulara erişilmiştir. Taşıyıcılık noktasında perdelerin önemli görev üstlendiği binalarda yanal yükün karşılanmasında söz konusu elemanlar devrede olduğundan kolonlarda meydana gelen bölgesel göçmeler kapasite eğrisinde ciddi anlamda dikkat çekmemiştir. Kolonlarda yaşanan bölgesel göçmeler mafsalların detaylı olarak incelenmesi sonucunda tespit edilmiştir. Etriyelerin yetersiz olduğu, beton basınç mukavemetinin düşüklük arz ettiği binalarda ciddi oranda kesme hasarları ortaya çıkmıştır. Deprem anında oluşan yüklerin kolonlar aracılığıyla taşındığı binalarda sargı aralığının ve beton dayanımının deplasman eğrisinde önemli etkisinin olduğu tespit edilmiştir. Afet Bölgelerinde Yapılacak Yapılar Hakkında Yönetmelik 1975 (ABYYHY-1975) uyarınca tasarım esasları belirlenen binalarda az miktarda yatay yük oluşması beklendiğinden büyük deplasmanlar oluşmuş ve gereken güvenlik seviyelerine göre tasarlanan yapılarda öngörülen düşük yatay yük sebebi ile büyük deplasman istemleri belirlemiştir ve dolayısı ile yeterli güvenlik düzeyinin elde edilemediği görülmüştür. Kamuya ait binaların genellikle dikdörtgen olarak tasarlandığı ve kolonların uzun kenarının binaların uzun olan kesitinde olduğu saptanmıştır. Söz konusu uygulamanın ciddi anlamda problem teşkil ettiği belirtilmiş ve binaların uzun yönünde moment taşıma kapasitesinin düşük olmasına ve kuvvetli kiriş-zayıf kolon mevcudiyetine neden olduğu ifade edilmiştir.

Tezcan ve ark. (2005) tarafından yapılan çalışma ile Sıfır Can Kaybı Metodu hakkında genel bilgiler verilmiş ve söz konusu yaklaşımın icra edilebilirliği, maddi anlamdaki zorunluluğu ve kazandıracığı olumlu etkiler ele alınmıştır. Olası bir depreme tam teşekküllü hazır hale gelebilmek için kamu kurumlarının ve yerel kuruluşların yapması gereken vazifeler, risk ve kriz yönetimi hususları olarak sunulmuştur. Deprem esnasında veya depremden sonraki süreçte yapılacak müdahaleler ve gereksinimlerin giderilmesi amacıyla uygulanan tüm yardımlar kriz yönetimi olarak tanımlanmıştır. Depremde oluşabilecek can ve mal kayıplarının önlenmesi amacıyla yapılan tüm önlemler ise risk yönetimi olarak ifade edilmiştir. Ayrıca, risk yönetimi 3 başlık altında toplanmıştır:

- Eğitim seferberliği
- Yeni yapıların güvenli bir şekilde inşa edilmesi
- Mevcut yapıların güçlendirilmesi yerine Sıfır Can Kaybı Yöntemi.

Çalışmada, Türkiye’de 2000 yılının öncesinde yapılmış bir binanın Afet Bölgelerinde Yapılacak Yapılar Hakkında Yönetmelik 1997 (ABYYHY-1997) uyarınca analize tabi tutulması halinde güvenlik açısından ciddi sorunların ortaya çıkacağı belirtilmiştir. Söz konusu problemin sebebinin de ABYYHY-1997 yönetmeliğindeki güvenlik seviyesinin oldukça üst seviyelere çıkartılması olduğu belirtilmiştir. Yalnızca İstanbul ilindeki binalar dikkate alındığında bile detaylı bir inceleme yapılarak risk durumlarının belirlenmesinin hem uzun zaman alacağı hem de ciddi maliyetler oluşturacağı ifade

edilmiştir. Bahse konu binaların güçlendirilmesi aşamasında hak sahipleri arasında yaşanan sorunlar ve lojistik problemlerin de önemli bir handikap olduğu belirtilmiştir. Söz konusu problemlerin ortadan kaldırılmasının birçok girift denklemlerin çözümüne, devasa finansal kaynaklara ve oldukça fazla miktarda teknik uzmana ihtiyaç olduğu belirtilerek bu olguya basit bir çözüm olması bakımından Sıfır Can Kaybı Metodu ileri sürülmüştür. İstanbul ilinde bulunan bina sayısının diğer illere nispetle sayıca fazla olması nedeniyle yaşanabilecek ciddi büyüklükteki bir depremde söz konusu binaların %4 ünün kısmi olarak göçeceği veya toptan yıkılacağı dile getirilmiştir. Bu noktadan hareketle İstanbul ilindeki tüm binaların risk değerlendirmesinin yapılmasının yerine kısmi veya toptan göçmesi öngörülen binaların tespit edilerek değerlendirilmesi ve gerekli aktivasyonların alınmasının uygun olacağı ifade edilmiştir. Yapılan çalışmada, binaların göçme durumlarının saptanması iki merhalede anlatılmıştır. İlk aşamada yalnızca gözlemlere dayanarak perde, kolon ve taşıyıcı duvarların boyutlarına ve yerleşim düzenlerine bakılmak suretiyle göçme riski tespit edilmiştir. Sonraki aşamada ise göçmesi muhtemel olan binalar ilmi ve teknik veriler dikkate alınarak belirlenmiştir. Söz konusu çalışmada ileri sürülen metodun binaların yoğunluklu olarak bulunduğu alanlarda, yönetmelik hükümlerince detaylı analizlerinin yapılmasından ziyade göçmesi muhtemel olan binaların kısa sürede ve düşük maliyetle tespit edilmesi amacıyla bir çözüm önerisi olarak dikkate alınması kamu kurumlarına ve yerel kuruluşlara tavsiye edilmiştir.

Çağlayan ve Boduroğlu (2007) tarafından yapılan çalışmada, 1992 yılındaki Erzincan, 1998 yılındaki Ceyhan, 1999 yılındaki Düzce ve İstanbul depremleri neticesinde farklı düzeyde hasar görmüş binalara Japon Sismik İndeks Yöntemi uygulanmış ve ABYYHY-1997 yönetmelik hükümleri kapsamında yer alan Deprem Güvenliği Tarama Yöntemini (DGTY) kullanarak Zeytinburnu ilçesinde bir çalışma uygulamaya koymuşlardır. Çalışma dahilinde 2401 tane binaya DGTY tatbik edilmiştir. Zeytinburnu ilçesinde yer alan 12 binanın pushover analizi neticeleri ile bahse konu çalışmanın sonuçları mukayese edilmiştir. Yapılan çalışma sonucunda pushover analizi sonuçları ile DGTY uygulanan binalara ilişkin analiz neticelerinin paralellik gösterdiği saptanmıştır. Bu noktadan hareketle 6 kata kadar binalarda DGTY'nin rahatlıkla değerlendirme amacıyla kullanılabilmesi ifade edilmiştir.

Sucuoğlu (2007) tarafından geliştirilen "Sokaktan Tarama Yöntemi" adı verilen yöntem ile 6 kata kadar olan mevcut betonarme binaların detaylı inceleme yapılmaksızın dış mekân gözlemleri ile tespit edilebilen parametreler uyarınca bina risk önceliklendirmesi yapılmıştır. Söz konusu çalışmada yapı kalitesi, ağır çıkma durumu, yumuşak kat varlığı ve kat sayısı dikkate alınarak her bir bina için risk sıralaması oluşturulmuştur. Bahse konu yöntem Küçükçekmece, Fatih ve Zeytinburnu ilçelerindeki binaların performans skorlarının tespiti amacıyla kullanılmıştır. 1999 yılında Düzce'de hasar görmüş olan yapılardan alınan veriler kullanılmak suretiyle yöntem kalibre edilmiştir. 5-6 katlı betonarme binaların büyük çoğunluğunu oluşturduğu Fatih ilçesindeki 16.523 tane binanın 3.648 adedinin risk seviyesinin oldukça yüksek olması sebebiyle detaylı incelemelerin yapılması açısından

bahse konu ilçenin uygun olduğu ifade edilmiştir. Söz konusu çalışmada yüksek risklilik arz eden binaların yer kabuğundaki hareketlere ve bu hareketlerin büyüklüğüne bütünüyle bağlı olmadığı saptanmıştır.

Kutanis ve ark. (2007) tarafından yapılan 1999 Marmara Depremi'nde yıkılan bir binayı ele aldıkları çalışmada deplasman temelli metotlar ile söz konusu depremde hasara uğramış veya göçmüş binaların tespit edilip edilemeyeceği incelenmiştir. Çalışma kapsamında dikkate alınan bina Sakarya ilinde yer alan ve zemin+4 normal kattan oluşmaktadır. Söz konusu bina, mühendislik hizmeti almış ve görsel kalite anlamında iyi düzeydedir. Bahse konu binanın taşıyıcı sistemi betonarme çerçeve olup asansör boşluğunun etrafında da bir perde yer almaktadır. Risk analizinde elastik ötesi nonlinear pushover kullanılmıştır. Çalışmanın ilk aşamasında zemin özellikleri incelenmiş, benzer yapısal özelliği ve büyüklüğü olan 6 deprem kaydından elde edilen tepki ve tasarım spektrumları mukayese edilmiştir. SeismoStruct yazılım programı vasıtası ile analizler yapılmıştır. Çalışma neticesinde Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik 2007 (DBYBHY-2007)'de yer alan tasarım spektrumu ile benzer yapısal özelliği ve büyüklüğü olan 6 deprem kaydından elde edilen tepki ve tasarım spektrumlarının büyük oranda farklılık arz ettiği ve zemin hâkim periyodu ile spektral ivme genliğinin DBYBHY- 2007'de verilen sınır değerleri geçtiği tespit edilmiştir. Dolayısı ile binalara ilişkin performanslar belirlenirken tasarım spektrum değerlerinin belirlenmesinin zaruri olduğu ifade edilmiştir. DBYBHY-2007'de yer alan metoda göre deprem isteminin belirlenmesinde temel alınan başlangıç doğrusunun kötü sonuçlar verdiği veya perdeli binalara ilişkin performansların belirlenmesi için uygun olmadığı dile getirilmiştir.

Kömür ve ark. (2007) Federal Acil Durum Yönetim Kurumu 310 (FEMA-310) ile Betonarme Binaların Deprem Güvenliğinin Belirlenmesi isimli çalışmada; İstanbul ili Avcılar ilçesinde yer alan 4 katlı betonarme bir binayı risk analizi için FEMA-310 metodu vasıtası ile incelemeye tabi tutmuştur. Çalışma neticesinde bahse konu metotta grift ve detaylı hesaplamaların yapılıyor olması ve süneklige ilişkin bazı hususların düşey taşıyıcı elemanlar temelinde göz ardı edilmesi nedeniyle değerlendirilen binaya ilişkin hatalı sonuçlar elde edildiği belirtilmiştir.

Bal ve ark. (2007) yaptıkları çalışmada, mevcut betonarme binaların göçme olasılıklarını kısa sürede ve yüksek doğrulukla tespit edebilen P25 Metoduna ilişkin prosedürleri ortaya koymuştur. Yöntemde binaların hasarlarının kademelendirilmesinden ziyade oluşabilecek can kayıplarını engellemek adına söz konusu binaları güvenli ya da güvensiz olarak sınıflandırmak için çok sayıda parametre dikkate alınmıştır. 14 farklı parametreyi (korozyon varlığı, ağır çıkma durumu, sargı özelliği, beton mukavemeti vb.) bünyesinde bulunduran temel yapısal puanı (P1), kısa kolon puanı (P2), yumuşak ve zayıf kat puanı (P3), çıkmalar ve çerçeve süreksizliği puanı (P4), çarpışma puanı (P5), sıvılaşma potansiyeli puanı (P6), toprak hareketleri puanı (P7) arasından en düşük değerli olan puan, düzeltme katsayıları vasıtasıyla çarpılarak nihai puan elde edilmektedir. Nihai puanın sınır değerinin aşağısında olması halinde binalar güvensiz, yukarısında olması halinde ise güvenli olarak

tasnif edilmektedir. Herhangi bir deprem tecrübesi yaşamış 289 adet mevcut betonarme bina ile DBYBHY-2007 uyarınca modellenmiş 22 adet bina dikkate alınarak söz konusu yöntemin kalibrasyonu yapılmıştır. Göçme durumunda olan 17 binanın nihai puanlarının sınır puanın aşağısında olması söz konusu metodun bilimsel anlamda sağlam temellere oturduğunu ve güvenilir olduğunu ispatlamıştır. Diğer taraftan, göçme olasılığı yüksek olan binaları sınıflandırırken tespit edilen sınır puanı, kati olarak belirlemekten ziyade mali şartları da gözetenek bir seviye belirlemenin daha doğru olduğunun altı çizilmiştir.

Çelik ve ark. (2007) tarafından icra edilen çalışma dâhilinde Doğu ve Batı Avrupa'daki bazı ülkelerde yer alan konsolosluk binaları için risk önceliklendirilmesi gerçekleştirilmiştir. Kanada Ulusal Araştırma Birliği tarafından yayımlanan Kanada Sismik Tarama Metodunun farklı taşıyıcı sistem özelliklerine sahip olan binalara uygulanmasının diğer hızlı sismik değerlendirme yöntemlerinin birçoğundan pozitif anlamda ayrılmasına sebebiyet verdiği ifade edilmiştir. Binaların taşıyıcı sistem karakteristikleri, malzeme özellikleri, yapısal anlamdaki düzensizlikler, yapısal olmayan öğelerin doğurabileceği riskler, bölgenin sismisitesi, yerel zemin özellikleri, bina yaşı, bina önem durumu, binada ikamet edenlerin sayısı vb. parametreler göz önünde bulundurularak yapısal indeksler ve yapısal olmayan indeksler belirlenmektedir. Bu metotta binanın yer aldığı bölge için belirlenen maksimum yer ivmesi, yerel zemin özellikleri, döşeme tipi, yapısal anlamdaki sorunlar vb. kriterleri bünyesinde barındıran yapısal indeks (SI) ile beraber yapısal olmayan parametreleri (mekanik ve elektrik tesisat elemanları, parapet vb.) içeren yapısal olmayan indeksin (NSI) toplanması neticesinde hesaplanan sismik öncelik indeksi (SPI) uyarınca binaların risk öncelik durumları belirlenmiştir. Bu risk önceliklendirmesine göre detaylı analizlerin yapılması gereken binaların belirlenmesi hedeflenmektedir. Bu risk önceliklendirme kademeleri aşağıdaki şekliyledir:

- SI ya da NSI 1,0~2,0 yeterli deprem güvenliği (YDG)
- SPI < 10 düşük öncelikli binalar (DÖB)
- SPI 10~20 orta öncelikli binalar (OÖB)
- SPI > 20 yüksek öncelikli binalar (YÖB)
- SPI > 30 çok tehlikeli binalar (ÇTB)

Gülay ve ark. (2008) yaptıkları çalışmalarında, binaların hızlı sismik değerlendirilmesi için ortaya atılan P25 Metodunun kalibre edilmesi amacıyla 370 adet bina üzerinde değerlendirme işlemi yapmışlardır. Bu doğrultuda 7 farklı göçme durumunu temel alarak farklı malzeme türleri, yerel zemin özellikleri, yapısal anlamdaki düzensizlik parametrelerini bünyesinde barındıran metod uyarınca söz konusu yöntem kalibre edilmiştir. Önceki yıllarda deprem tecrübesi yaşamış ve farklı seviyelerde hasar almış 370 adet binaya bahse konu yöntem uygulanmış ve ileri sürülen metodun yüksek doğrulukla göçme durumunda olan binaları tespit edebildiği gösterilmiştir. Analitik uygulamalarla son hali teşkil edilen metod daha sonra İstanbul ili Kadıköy ilçesinde bulunan 50 civarı

binaya da tatbik edilmiş ve bahse konu binalara ilişkin hem yerinde hem de projeleri üzerinden detaylı incelemeler yapılmak suretiyle kıymetli bilgiler elde edilmiştir.

İnel ve ark. (2008), orta yükseklikli betonarme binaların elastik ötesi davranışlarını göz önünde bulundurarak yaptıkları çalışmalarında önemli bilgiler ortaya koymuşlardır. Bu doğrultuda 14 adet binaya ilişkin etriye mesafeleri 10cm ve 20cm alınmak suretiyle her iki deprem doğrultusu uyarınca 56 farklı model teşkil edilmiştir. Beton sınıfı BS16, donatı sınıfı ise S220 olarak tayin edilmiştir. Her bir bina için pushover analizi ve zaman tanım aralığında dinamik analiz yapılmıştır. Zaman tanım alanında yapılan hesap için ülkemizde yaşanmış 20 farklı özellikteki deprem kayıtları dikkate alınmıştır. Çalışmanın neticeleri incelendiğinde neredeyse hiçbir bina Hemen Kullanım (HK) performansını sağlayamamıştır. Yalnızca etriye mesafeleri 10cm olan binaların %33'ü Can Güvenliği (CG) performansını sağlamıştır. %40-%65 aralığındaki binalar, etriye mesafelerine göre Göçmenin Önlenmesi (GÖ) performansını sağlamıştır. Bu çalışmasının sonucunda ABYYHY-1975 yönetmeliğindeki kıstaslar dikkate alınarak teşkil edilmiş binaların yanal mukavemetleri ve yanal rijitlik kapasitelerinin yetersiz kalması nedeniyle büyük deplasmanlar yaparak hasara neden oldukları tespit edilmiştir. Enine donatı mesafelerinin performans seviyesi noktasında önemli oranda etki yaptığı da tespit edilen hususlardan olmuştur. Tasarlanan modellerin hemen hemen hepsinde zayıf kolon-kuvvetli kiriş problemi ortaya çıkmıştır ki bu da ciddi anlamda binalarda göçmeye sebebiyet veren bir parametredir. Çalışma neticesinde yeniden inşa edilecek binalarda yanal mukavemet ve yanal rijitliklerin artırılması tavsiye edilmiştir.

Yüksel (2008) tarafından yapılan çalışmada mevcut betonarme binaların, gerçekleşen bir deprem neticesinde hızlı bir şekilde değerlendirilmesi hususu araştırılmıştır. Yapılan çalışmada, olası bir depremin akabinde binalarda oluşan hasarların belirlenmesi, binaların kullanılabilir olup olmadığının tespit edilmesi ya da tahliye edilmek suretiyle güçlendirme icra edilmesi veya yıkımının gerçekleştirilmesi durumları için bir karar alma mekanizması ortaya konulmuştur. Yapısal ve yapısal olmayan hasarlara ilişkin detaylı açıklamalar yapılmış ve söz konusu deprem hasarlarının nelerden kaynaklandığı, bu hasarlara nasıl çözümler getirilebileceği ve bu hasarların binanın performansını nasıl etkilediği hususları ele alınmıştır. Ayrıca, yaşanabilecek bir depremin öncesinde ve sonrasında yapılacak hazırlıklara ve acil destek uygulamalarına ilişkin zaruriyet ifade edilmiş ve deprem sonrasında mevcut binaların hızlı ve yüksek doğrulukla değerlendirilmesinin uzman teknik elemanlarca yapılmasının uygun olacağı dile getirilmiştir.

Mahmoodzadeh ve ark. (2008) binaların göçmesine neden olan parametreleri incelemek suretiyle bir göçme modu-etki analizi ortaya koymuşlar ve her bir nedenin önceliklendirilmesi noktasında araştırma yapmışlardır. Çalışmanın sonuçları ile depreme karşı binaların sergiledikleri davranışları alakalandırarak ileri sürülen yöntem dâhilinde her bir binayı evet-hayır sınıflandırması uyarınca seviyelendirmişlerdir. Geliştirilen yöntem uyarınca kullanılan formlar ile söz konusu binaların depreme karşı hassasiyetleri tespit edilmiştir.

Gülay ve ark. (2010) tarafından P25 Metodunun saha uygulaması olarak icra edilen çalışmada, İstanbul'un Kadıköy ilçesinde yer alan 40 adet bina göz önünde bulundurulmak suretiyle söz konusu yöntemin kalibrasyonu sağlanmıştır. Değerlendirmeye tabi tutulan binaların tamamı 1960 senesinin evvelinde inşa edilmiştir. Projesi bulunmayan binaların rölöveleri çizilmiş iken hâlihazırda projesi olan binaların söz konusu projelere uygunluğu sınanmıştır. Bahse konu binaların beton mukavemetleri ve donatı dayanımları belirlenmiştir. P25 Yöntemi kriterlerince değerlendirilen ve neticesinde nihai puanı düşük olan binaların çoğunda yumuşak kat varlığı tespit edilmiştir. Bunun nedeninin de binaların zemin katlarında dükkân varlığı sebebiyle üst katlara nispetle zemin kat yüksekliğinin fazla olması gösterilmiştir. Ayrıca binalarda kısa kolon mevcudiyetinin de nihai puanları ciddi anlamda etkilediği ifade edilmiştir. Bu olumsuzlukların yanında dolgu duvarların yanal rijitliğe pozitif anlamda katkı sağladığının da unutulmaması gerektiğinin altı çizilmiştir. Sonuç olarak bahse konu yöntemin net sonuçlar vermediği ancak risk önceliklendirilmesi açısından kısa sürede yüksek doğruluk elde edilmesi hasebiyle can kayıplarının önüne geçilmesi bakımından ciddi önem arz ettiği vurgulanmıştır.

Ersin (2010) tarafından yürütülen çalışmada, kamuya ait olan 3 adet okul, mevcut yönetmeliklerde yer alan kriterler uyarınca analize tabi tutulmuştur. Söz konusu çalışmada Japon Sismik İndeks Yöntemini kullanarak bahse konu okulların 1. ve 2. kademe değerlendirmelerini yapmış ve deprem performansına ilişkin neticeleri tablolar halinde sunmuştur.

Baran ve ark. (2011) tarafından yapılan çalışmada, İzmir ili Balçova ilçesinde 7.268, Seferihisar ilçesinde ise 2.922 olmak kaydıyla totalde 10.550 adet binaya ait veriler toplanmış ve söz konusu binaların deprem açısından hızlı sismik değerlendirilmesinin yapılması için toplanan datalar İzmir Büyükşehir Belediyesi veri havuzuna gönderilmiştir. Bahse konu binalara ait veriler olası bir afet öncesinde gerekli önlemlerin alınması amacıyla taşıyıcı sistem özelliklerine göre tasnif edilmiştir. Farklı muhteviyatlardaki yaklaşık 10.000 bina birinci ve ikinci kademe metotlar dâhilinde analize tabi tutulmuştur. Yapılan değerlendirmeler neticesinde birinci kademe değerlendirme yöntemleri için iki (az-çok) aşamalı, ikinci kademe değerlendirme yöntemleri için ise üç aşamalı (az-orta-çok) sınıflandırma verileri elde edilmiştir. Birinci kademede yer alan binalar büyük çoğunlukla tasnifi yapılan her iki grupta eşit miktarda iken, ikinci kademede orta grupta bulunan bina adedi miktarı söz konusu grubun büyük çoğunluğunu teşkil etmektedir.

Yakut ve ark. (2012) tarafından yürütülen çalışmada, ülkemizdeki mevcut yapı stoğunun olası bir depremde istenilen performansı sergileyemeyeceği düşüncesinden yola çıkarak söz konusu yapılara ilişkin hızlı sismik değerlendirme yöntemlerinin geliştirilmesi amacıyla yeni bir yöntem önerilmiştir. Ülkemizdeki yapıların büyük çoğunluğunu yığma ve betonarme yapıların teşkil etmesi sebebiyle bu çalışmada söz konusu yapılar dikkate alınmıştır. Önerilen yöntemin binaların çoğunlukla dış kısmından toplanan verilerle 1 ile 7 katlı betonarme binalara uygulanması halinde geçerli olacağı ifade edilmiştir. Söz konusu veriler: binanın taşıyıcı sistem türü, düşey elemanların süreksizliği, ağır

çıkma varlığı, bitişik nizamlılık durumu, kısa kolon mevcudiyeti vb. olarak sıralanabilir. Ayrıca, bahse konu çalışmada yığma binaların değerlendirilmesi amacıyla binaların kat adedi ve yer aldığı deprem bölgesi uyarınca söz konusu binalara bir başlangıç skoru verilmektedir. Akabinde binada bulunan olumsuzluk durumlarının dikkate alınması suretiyle sonuç skoru hesaplanmaktadır. Olumsuzluk parametresi olarak dikkate alınan veriler ise malzeme ve işçilik kalitesi, binanın konumu, taşıyıcı duvarların konumları ve boyutları, hatıl varlığı ve geçirmiş olduğu depremler neticesinde oluşan hasarlardır.

İlki ve ark. (2014) tarafından ortaya atılan PERA Yönteminde binalara ait genel performans; kolonların talep/kapasite eğrileri, göçme modları (sünek/gevrek) ve (eksenel ve kesme) gerilmeleri değerlendirilerek hesaplanmıştır. Bununla beraber kritik katta (genellikle zemin kat) oluşan deplasmanların binanın toplam performansını büyük ölçüde etkilemesi sebebiyle söz konusu deplasmanlar da dikkate alınan önemli bir parametre olmuştur. İleri sürülen yöntem kıstasları ile yönetmelikler uyarınca yapılan detaylı analizler 672 adet betonarme bina özelinde mukayese edilmiş ve olumlu anlamda sonuçların paralellik gösterdiği ifade edilmiştir.

Özhendekçi ve Özhendekçi (2012) yaptıkları çalışmada Bingöl depremi neticesinde hasara uğramış orta ve az katlı betonarme binalarda faydalanmak suretiyle çoklu lineer regresyon analizini baz alan hızlı sismik değerlendirme metodunu açıklamışlardır. Söz konusu çalışmada bina önem katsayısı, bina çerçeve türü, kısa kolon mevcudiyeti ve yumuşak kat varlığının değerlendirme aşamasında sonuçları ciddi anlamda etkileyen olumsuzluklar olduğu ifade edilmiştir.

Çaycı (2012) tarafından yürütülen çalışmada, deprem sonrası hasara uğramış 113 betonarme binanın karakteristik özelliklerini ifade eden beton mukavemeti, donatı özellikleri, düşey taşıyıcı elemanların boyutları ve konumları vb. parametreler bir araya getirilerek hasarla olan ilişkisi incelenmiştir. Diğer taraftan yerel zemin karakteristiklerinin saptanması için standart penetrasyon ve MASW (Yüzey Dalgalarının Çok Kanallı Analizi) deneyleri icra edilmiştir. Toplanan yapısal verilerden hareketle binaların hızlı sismik değerlendirme skorları hesaplanmış ve mevcut durumdaki hasar seviyeleri ile uyumları test edilmiştir.

Adam ve Achs (2012) tarafından yapılan çalışmada, RVS'ye dayalı olarak Viyana şehrinde bulunan tarihi tuğla-yığma binaların sismik değerlendirmesi ele alınmıştır. RVS metodolojisi, tutarlı tipolojileri dikkate alınarak bu çok özel bina türleri için benimsenmiş ve sonuç olarak sismik değerlendirmenin geçerliliğini ve kalitesini artırmışlardır. Bu bağlamda, incelenen yapının düzenliliği, korunma durumu ve geometrisi gibi yapı ile ilgili parametreler değerlendirilmiştir. Ek olarak, depremin neden olduğu hasarın yapı üzerindeki insani ve ekonomik etkisi, maruz kalan kişi sayısı ve yapının önemi değerlendirilerek hasarla ilgili faktörlerle bütünleştirilmiştir. Bu iki parametre setinin her birinin elde edilen puanına bağlı olarak, incelenen bina dört güvenlik açığı sınıfından biri ile sınıflandırılmıştır. Ayrıca, L'Aquila 2009 depremiyle karşılaştırılabilir bir sismik olayın hasar potansiyeli, EMS-1998'e göre RVS metodolojisinin sonuçları ve hasar dereceleri ile ilişkilendirilerek

tahmin edilmiştir. Büyük ölçekli bir incelemede, Viyana'nın 20. bölgesindeki 375 bina sismik olarak değerlendirilmiştir. Ortaya çıkan hasar senaryoları haritaları, acil durum ve tahliye planlamasının yanı sıra sismik yüklemeye karşı savunmasız olan kritik yapıların tanımlanması için yararlı bilgiler çalışmada verilmiştir.

Işık ve Kutanis (2013) tarafından yapılan çalışmada, Bitlis ilinde bulunan mevcut betonarme bina stokunu, hızlı sismik değerlendirme yöntemi olan P25 Metodu ile değerlendirmeye tabi tutmuş ve risklilik arz eden binaları belirleyerek daha kapsamlı yöntemler uyarınca analiz yapmış ve söz konusu ilin çeşitli lokasyonlarından belirlenen binaları derlemek suretiyle hesaplamalar icra etmiştir. P25 Hızlı Değerlendirme Yöntemi kapsamında araştırılan toplam 94 adet binanın %4'ünün göçme durumunda olduğu, %50'sinde göçme riskinin bulunmadığı, %46'sı için ise detaylı analiz yapılmasının elzem olduğu ifade edilmiştir.

D'Ayala (2013) tarafından yapılan çalışmada, dünya çapında yıkıcı depremsellikten etkilenen bölgelerdeki yığma yapıların; mevcut bina stokunun büyük çoğunluğunu temsil ettiği belirtilmiştir. Bununla birlikte, iyi inşa edilmiş kâgir yapıların yüksek depremselliğe sahip bölgelerde bile yüzyıllardır ayakta kalabildiği ifade edilmiştir. Geçmişte, yığma yapıların sismik kırılma değerlendirmesinin hasar verilerinin olay sonrası toplanmasına dayanan ampirik yöntemler kullanılarak yapıldığını belirtmiştir. Bu yaklaşımın, yapısal davranışın gözlenen hasar ile kolay bir şekilde ilişkilendirilmesine ve sismik güçlenmenin sismik direnç üzerindeki etkisinin ölçülmesine izin vermediğini de dile getirmiştir. Yığma binaların sismik kırılma değerlendirmesiyle ilgili ana konuların ilk incelemesinden sonra, yığma yapılar için kapasite eğrilerini türetmek için sınır durum analizi ve çökme mekanizmalarına dayalı bir prosedürün mantığını ve algoritmasını sunmuştur. Kapasite spektrumu yönteminin metodolojisi ve performans dayalı değerlendirme yönteminin ardından prosedürün güvenlik açığı ve kırılma fonksiyonlarını türetmek için nasıl kullanılabileceğini göstermiştir.

Kılıç (2014) tarafından yapılan çalışmada, Balıkesir il merkezi sınırları içerisinde yer alan 50 adet konut türü bina, betonarme binaların hızlı sismik değerlendirilmesinde kullanılan P25 Metodu kullanılmak suretiyle değerlendirmeye tabi tutulmuştur. Dikkate alınan 50 binadan farklı özelliklere haiz olan 15 tanesi DBYBHY-2007'de yer alan Eşdeğer Deprem Yüğü Yöntemi uyarınca analiz edilmiş ve deprem performansları hesaplanmıştır. P25 Metodu ve Eşdeğer Deprem Yüğü Yönteminden elde edilen neticeler mukayese edilmiş ve sonuçların büyük oranda paralellik gösterdiği ifade edilmiştir. Diğer taraftan, bazı binalar için de söz konusu iki yöntem arasında uyumsuzluklar olduğu görülmüştür. Bahse konu uyumsuzluğun P25 Metodunun bazı kabuller ve yaklaşımlar yaparak değerlendirme işlemini icra etmesinden kaynaklandığı dile getirilmiştir. Ayrıca, P25 Metodu ile daha doğru neticelere erişebilmek için yapılabilecek düzenlemeler hususunda tavsiyeler sunulmuştur.

Perrone ve ark. (2015) tarafından yapılan çalışmada, hastane binaları için bir güvenlik indeksi belirlemek amacıyla hızlı bir görsel tarama yöntemi önerilmiştir. Bu doğrultuda yeni geliştirilen yöntem ile sistematik bir sokak araştırması sırasında binaların zarar görebilirliğini etkileyen ana parametreleri değerlendirilerek bir risk indeksi belirlenmesi sağlanmıştır. Bu yöntem, farklı sismik bölgelerde bulunan iki İtalyan hastanesine uygulanmış ve sonuçlar, bir itme analizinden elde edilen benzer bir indeks ile karşılaştırılmıştır. Son olarak bu çalışmada önerilen RVS Yöntemi, 2009 L'Aquila Depremi ve 2012 Emilia Depremi'nde hasar gören iki hastaneye de uygulanmıştır.

Shah ve ark. (2016) tarafından yapılan çalışmada, bir şehirdeki çok sayıda yapının sismik hasar görebilirliğini tahmin etme yönteminin RVS olduğu ifade edilmiştir. Binaların öngörülen sismik performansının yapısal tipolojiye (çerçeve, perde duvar, monolit, dolgu), malzemeye (çelik, betonarme, donatılı/donatısız duvar, ahşap, kompozit), kullanılan tasarım yöntemlerine ve diğer detaylara dayandığını belirtmiştir. Tahminlerin, uzman görüşlerine, itme analizlerine, dinamik tepki çalışmalarına ve benzer binaların geçmişteki sismik olaylardaki performansına dayandığını da belirtmişlerdir. Binaların çökme olasılığını ölçmek için bir puanlama sistemi kullandıklarını ve diğer faydalı veya zararlı bina özellikleri, zemin koşulları ve bitişik yapıların varlığı nedeniyle puanların değiştirilebilir olduğunu ifade etmişlerdir. Mükemmel bir yöntem olmasa da bir şehrin hangi bölgelerinin genellikle diğerlerinden daha savunmasız olduğunu belirlemede söz konusu yöntemin çok faydalı olduğunu belirtmişlerdir. Ayrıca bu çalışmada hızla genişleyen Suudi Arabistan'daki eski ve yeni binaların farklılıklarını değerlendirmek amacıyla iki farklı zaman diliminde inşa edilen konut binasının depreme karşı kırılabilirliği RVS uygulamaları ile belirlenmiş ve sonuçlar mukayese edilmiştir.

Kaplan ve ark. (2018) yaptıkları çalışmada orta yükseklikteki betonarme binaların deprem performanslarını belirlemek için geleneksel yönetmelik tabanlı yöntemlere göre daha hızlı, daha ucuz ve daha güvenilir bir değerlendirme imkânı sunan AURAP 2018 Yöntemini ortaya atmışlardır. Uygulanan yöntemin kalibrasyonu için 1999 Kocaeli depreminde çöken 39 bina projesi dikkate alınmıştır. Çalışma kapsamında Eskişehir ilinden 55 bina dikkate alınmış ve kalibre edilmiş olan 39 bina ve yönetmelik tabanlı analiz yöntemleri ile mukayese edilmiştir. Sonuçların %83 oranında doğruluk sağlamış olması sebebiyle önerilen yöntemin mevcut orta yükseklikteki betonarme binaların deprem performansının belirlenmesi için uygulanabilir hızlı bir değerlendirme yöntemi olduğu kanıtlanmıştır.

Pardalopoulos ve ark. (2018) tarafından yapılan çalışmada, sismik talepler ve sismik kapasiteleri belirleyen basit yöntemler vasıtasıyla saha mühendisleri için bir kılavuz olarak kullanılabilir olan bir değerlendirme akış şemasının geliştirilmesi sağlanmıştır. Bu doğrultuda, yapının malzeme ve basit geometrik özellikleri kullanılarak kapalı formlar oluşturulmuştur. Diğer taraftan, önerilen hızlı değerlendirme yönteminin yapılarda oluşabilecek çökme mekanizmalarını ortadan kaldırabilecek uygun güçlendirme yönteminin seçimine rehber olabileceği de ifade edilmiştir.

Ayrıca, önerilen hızlı değerlendirme yöntemi için de geçmişte yaşanan şiddetli depremler sırasında farklı düzeylerde hasar görmüş binalar dikkate alınarak hasar seviyeleri karşılaştırılmış ve elde edilen sonuçların tutarlı ve doğru olduğu ortaya konulmuştur.

Mevcut yapı stoku envanter çalışması kapsamında betonarme yapıların hızlı değerlendirilmesine ilişkin olarak 6306 sayılı Afet Riski Altındaki Alanların Dönüştürülmesi Hakkındaki Kanun kapsamında yer alan Riskli Yapıların Tespit Edilmesine İlişkin Esaslar 2019 (RYTEİE-2019) Yönetmeliğinin EK-A kısmında belirtilen hususlar uyarınca birinci aşama değerlendirme yöntemi uygulanarak binanın fenotip olarak incelenmesi ve kısmen yapının içinden alınacak kısıtlı bilgilerle betonarme binaların risklilik durumlarının ve/veya önceliklerinin tespit edilmesi doğrultusunda bir ön bilgi edinme işleminin tesis edilmesi sağlanmıştır. İkinci aşama değerlendirme yönteminde ise yapının detaylı olarak incelenmesi; karot numuneleri alınarak beton dayanımı tespiti, eleman boyut ve detayların saptanması suretiyle kapsamlı bir değerlendirme işlemi uygulanması öngörülmüştür.

Coşkun ve ark. (2019) tarafından yapılan çalışmada, betonarme yapılarda detaylı incelemeye dayalı hızlı değerlendirme yöntemi önerilmiştir. Önerilen bu yöntem için 545 adet bina detaylı olarak incelenmiştir. Mevcut ayrıntılı değerlendirme sonuçlarından 400'ü önerilen hızlı sismik değerlendirme yöntemini eğitmek için kullanılmıştır. İlk olarak söz konusu metod için değişkenler (kat sayısı, zemin durumu, bina yaşı vb.) seçilmiştir. Bu değişkenler için sırasıyla en küçük kare regresyon analizi ve çok değişkenli doğrusal regresyon analizi yapılarak ceza puanları belirlenmiştir. Son olarak önerilen yöntemin performansını test etmek için kalan 145 betonarme bina kullanılmıştır. Sonuç olarak önerilen yöntemin doğruluk oranı, iki veri tabanı için de %83'e kadar ulaşmıştır.

Aldemir ve ark. (2020) tarafından yapılan çalışmada, donatısız yığma binaların risk önceliklerinin tespiti amacıyla yeni bir hızlı sismik değerlendirme yöntemi ortaya atılmıştır. Söz konusu yöntemde ikili lojistik regresyon kullanılmıştır. Veri havuzu yürürlükte olan yönetmelik hükümleri uyarınca detaylı analize tabi tutulmuş 543 tane donatısız yığma binadan teşkil edilmiştir. Yöntemde; kat sayısı, döşeme türü, düşeyde düzensizlik mevcudiyeti, görsel kalite, taşıyıcı malzeme türü, kat yüksekliği, bina oturum alanı parametreleri dikkate alınmıştır. Söz konusu parametreler için lojistik regresyon analizi aracılığıyla belirlenen katsayılar uyarınca olumsuzluk puanları belirlenmiştir. Veri havuzundan belirlenen 443 bina, olumsuzluk puanlarının tespiti; 100 bina ise söz konusu metodun test edilmesi amacıyla tasnif edilmiştir. Olumsuzluk puanlarının tespitinde kullanılan 443 bina için kapsamlı risk değerlendirme neticelerinden elde edilen risk durumları %93 doğrulukla tespit edilmiştir. Diğer taraftan, test için belirlenen 100 binada söz konusu oran %86 olmuştur.

Kassem ve ark. (2020) tarafından yapılan çalışmada, çeşitli ülkelerde kullanılan sismik değerlendirme yöntemleri üzerinde detaylı bir inceleme yapılmış ve diğer araştırmacılar tarafından yapılan çalışmalardan elde edilen bulgular özetlenmiştir. Söz konusu makelede araştırmacıları ve

uygulamacı mühendisleri gelecekteki çalışmalarını için kapsamlı bir rehber ve referans olarak kullanmaya motive edecek en yaygın ampirik ve analitik metodolojiler özlü bir şekilde sunulmaya çalışılmıştır.

Doğan ve ark. (2021) tarafından yapılan çalışmada, öncelikle mevcut binaların hızlı sismik güvenlik değerlendirme yöntemleri olan görsel tarama tabanlı (FEMA-154, RVS ve RYTEİE) ve kapasite bazlı (P25, Yakut, AURAP ve Durtes) yöntemler tartışılmıştır. Ayrıca hızlı bir değerlendirme yöntemi olmayan ancak detaylı performans analizi hükümlerini içeren TBDY-2018'e göre betonarme yapıların doğrusal ve doğrusal olmayan deprem performans prosedürlerini de vermişlerdir. Daha sonra, İstanbul ilinden belirlenen 30 mevcut betonarme bina, bahsedilen tüm bu yöntemlerle analiz edilmiştir. Bu çalışmada, 7 farklı hızlı sismik değerlendirme yönteminin sonuçları, avantaj ve dezavantajlar açısından TBDY-2018'in doğrusal ve doğrusal olmayan performansının sonuçlarıyla karşılaştırmışlardır. Son olarak FEMA-154, RVS ve RYTEİE yöntemlerinin binalara uygulanmasının daha hızlı olduğu ancak P25, Yakut, AURAP ve Durtes yöntemlerinin uygulanmasının daha fazla zaman aldığı ve daha ölçülü sonuçlar verdiği görülmüştür. TBDY-2018 doğrusal olmayan değerlendirme yönteminden elde edilen sonuçların diğer yöntemlere göre daha az ihtiyatlı olduğu görülmüştür. Ayrıca aynı binalar için TBDY-2018'de verilen doğrusal ve doğrusal olmayan değerlendirme yöntemlerinden elde edilen farklı sonuçlar da dikkat çekmiştir.

2.2. İnşaat Mühendisliği ve Yapay Zekâyı Bütünleştiren Çalışmalara İlişkin Kaynak Araştırması

Dünya genelinde iş gücünün büyük çoğunluğunu bünyesinde barındıran inşaat sektöründe ve dolayısıyla inşaat mühendisliği akademik camiasında yapay zekâdan yeterince yararlanılmadığı aşikardır. Fakat yapay zekanın diğer disiplinlerde sıklıkla kullanılması ve ortaya çıkan müspet ilerlemeler inşaat mühendisliğini de olumlu anlamda etkilemektedir. Bu durum da farklı disiplinleri, kaydedilen ilerlemelerden pozitif anlamda yararlanmaya itmektedir. Bu bölümde, yapay zekâ alanındaki gelişmelerin inşaat mühendisliğindeki uygulamaları araştırılmış ve bu doğrultuda literatürde icra edilen akademik çalışmalardan inşaat mühendisliği disiplini ile alakalı olanlar rafine edilerek aktarılmıştır.

Lee ve Nevatia (2004) tarafından yapılan çalışmada, kalibre edilmiş cephe görseli (yani düzeltilmiş doku) göz önüne alınarak binanın 3 boyut pencere yapısı çıkarılmıştır. Dikey ve yatay pencere yerleşiminin düzenliliğinden yararlanan bir profil projeksiyon yöntemi kullanarak pencereler (düzeltilmiş görüntüdeki dikdörtgenler) otomatik olarak belirlenmiştir. Tespit edilen pencereler 2D boyutlar ve görüntü dokusu bilgileri kullanılarak sınıflandırılmıştır. Belirlenen pencerelerin derinliği, pencere sınıflandırma bilgileri ve görüntü çizgisi özellikleri kullanılarak otomatik olarak

hesaplanmıştır. Yapılan yaklaşımda cephe pencerelerinin 3 boyutlu derinliklerini hesaplamak için tek bir cepheden alınan görüntülerin yeterli olduğu ortaya konulmuştur.

Choi ve ark. (2008) tarafından yapılan çalışmada, yakın zamanda geliştirilen bir çift görüntü sistemi ile inşaat projelerinin daha verimli, hızlı ve ucuz bir şekilde ilerlemesi için bilgi sağlama potansiyeline sahip olduğu ortaya konulmuş ve bu doğrultuda, hızlı bir 3B nesne tanıma tekniğinin yapısı (sistemi) ve bazı ön deneysel sonuçlar açıklanarak otomatik proje ilerleme, izleme ve kontrol sistemlerine uygulama olasılıkları ifade edilmiştir.

Malesa ve ark. (2010) tarafından yapılan çalışmada, inşaat mühendisliği yapılarının izlenmesine yönelik DIC (Digital Image Correlation) tekniğinin bir uyarlaması verilmiştir. Bu doğrultuda DIC sensörünün önemli bir rol oynadığı karmaşık, otomatik izleme sisteminin genel bir konsepti açıklanmıştır. Dış mekân ölçümlerini kolaylaştırmayı ve korelasyon analizini hızlandırmayı amaçlayan bazı yeni yazılım özellikleri de tanıtılmış ve uygulama örneği olarak, Nieporet (Polonya) 'deki bir demiryolu köprüsünün ölçüleri dikkate alınmak suretiyle deneysel sonuçlar elde edilmiş ve köprünün bir FEM modelinin yer değiştirmeleri ile karşılaştırılmıştır.

Zhu ve Brilakis (2010) tarafından yapılan çalışmada, görsel verilerden yararlanarak otomatikleştirilmiş kolon tespiti için yeni bir yöntem sunulmaktadır. Yöntem, kolonların sınır bilgilerini renk ve doku ipuçlarıyla birleştirerek söz konusu yapısal elemanları algılamaya çalışmaktadır. Kenar algılama ve Hough dönüşümü yoluyla bir görüntü veya video karesindeki uzun dikey çizgiler belirlenmiştir. Her bir çizgi çifti için sınırlayıcı dikdörtgen oluşturulmuş ve dikdörtgenin bir kolon şeklini andırması ve çizgi çiftinin içerdiği renk ve doku bilgi tabanındaki somut örneklerden biriyle eşleştirildiğinde, beton bir kolon yüzeyinin yerleştirileceği varsayılmıştır. Bu şekilde görüntülerde veya videolarda tek bir somut kolon tespit edilmiştir. Yöntem, gerçek görüntüler ve videolar kullanılarak test edilmiştir. Sonuçlar, yöntemin geçerliliğini belirtmek için manuel tespit sonuçlarıyla karşılaştırılmıştır.

Oskouie ve ark. (2015) tarafından yapılan çalışmada, tarama planlaması için veri kalitesine dayalı bir yaklaşım tanımlamak için görüntü işleme yöntemlerini nokta bulutu işleme teknikleriyle entegre etmek amacıyla yeni bir sistem önerilmiştir. Sistem sırasıyla şu adımları içermektedir: ticari olarak temin edilebilen bir insansız hava aracı (İHA) kullanarak bir hedefin görüntülerini yakalamak ve 3 boyutlu bir nokta bulutu oluşturmak, nokta bulutu kullanarak projenin geometrik bilgilerini tanımak, nokta bulutu kullanarak özellikleri çıkarmak (FOI), veri işleme gereksinimlerine ve çıkarılan özelliklere dayalı olarak birden çok tarama senaryosu oluşturmak, farklı tarama senaryolarının tekrarlamalı simülasyonu yoluyla en iyi tarama planını tanımlamak ve gerçek verileri kullanarak tarama planlarını oluşturmaktır. Diğer taraftan, çerçeve için var olan bir durum çalışmasının önceki verileri kullanılarak elde edilen sonuçlar değerlendirilmiştir. Durum çalışmasının veri kalitesi gereksinimlerinin, önerilen çerçeve kullanılarak karşılandığı sonucuna ulaşılmıştır.

Maalek ve ark. (2015) tarafından yapılan çalışmada, sağlam bir temel bileşen analizi tabanlı (PCA) segmentasyon algoritması aracılığıyla 3B/4B olarak teşkil edilmiş modeli otomatik olarak oluşturarak planlandığı gibi verilere olan bağımlılığı ortadan kaldırmak için yeni bir yöntem önerilmiştir. Önerilen sistem ayrıca 3B nokta bulutlarını yakalamak için kullanılan teknolojiden bağımsız olarak hareket etmiştir. Önerilen otomatik inşa edilmiş model oluşturma prosedürünün güvenilirliğini değerlendirmek için, Calgary Üniversitesindeki "Malzeme Mekaniği" laboratuvarından ve "Lisansüstü Öğrenci Yurdu" şantiyesinden iki grup LIDAR verisi toplanmıştır. İnşa edilen modelin planlanan model koordinat sistemine otomatik olarak kaydedilmesi için yeni bir yöntem önerilmiştir. Bu yöntemle yapısal elemanların planlanan ve gerçek boyutlarının uyumluluğu incelenmiştir. İki deneyin sonuçları, 3D/4D gibi yapı modelinin otomatik olarak oluşturulması için önerilen yöntemlerin uygulanabilirliğini ve yapısal elemanların boyut-uyum kontrolünün tutarlı bir şekilde yapılabildiğini göstermiştir.

Liebold ve Maas (2016) tarafından yapılan çalışmada, uygulamalı bir örnek dikkate alınarak inşaat mühendisliği alanında kullanılan malzemelerin yük testlerinde uygulanan bir fotogrametrik uzay-zamansal çatlak algılama ve analiz aracı ile doğrulanmıştır. Yük testi tekniği, değişken yük koşulları altında bir test nesnesinin monoküler görüntü dizilerine dayandırılmıştır. Bir dizinin ilk görüntüsü, sıfır yük altında bir referans görüntü olarak tanımlanmış, burada etki noktaları belirlenmiş ve üçgen düzensiz bir ağ yapısı içinde bağlanmıştır. Her devir için bu üçgenler, deformasyonları belirlemek için referans görüntü üçgenleriyle karşılaştırılmıştır. Özellik noktası izleme ve üçgen karşılaştırma sürecinin sonucu, çatlakların yerel tutarsızlıklar yoluyla tespit edilebildiği, konumlandırılabilirdiği ve ölçülebildiği mekânsal-zamansal olarak çözümlenmiş bir gerinim (yük) değeri alanı olarak ifade edilmiştir. Gerinim renk kodlu bir harita olarak görselleştirilmiştir. Ölçüm sistemini iyileştirmek ve parazitleri azaltmak için, her üçgenin gerinim değerleri bir filtreleme işleminde ele alınmıştır. Sonuç olarak en tutarlı değerlerin, uzamsal alanda iki taraflı bir filtre ve bir uzay-zamansal EOF (deneysel ortogonal fonksiyon) filtreleme tekniği ile elde edildiği ortaya konulmuştur.

Griffiths ve Boehm (2018) tarafından yapılan çalışmada, 3 CNN modeli ile demiryolu hattının 3 m²'lik bölümünde bulunan nesnelere tespiti için 275 insansız hava aracından (İHA) türetilmiş ve ücretsiz olarak erişilebilen çevrimiçi görüntüler üzerinde eğitilmiştir. Bunlar, Hızlı Tekrarlı Konvolüsyonel Sinir Ağı (RCNN) nesne algılama algoritmasına (ResNet ve Inception ResNet) ve aynı zamanda yeni bir aşamalı odak kaybı ağ mimarisine (RetinaNet) dayalı iki modeli içermektedir. Model performansı, üç doğruluk ölçütüne göre değerlendirilmiş ve ilk ikisi, 0,5 ve 0,1 eşiklerine sahip birlik üzerinden kesişim (IoU) içerdiği, sonuncusunun ise toplam yol uzunluğuna karşı nesne algılama önerileri kapsamındaki yol oranına dayalı olarak doğruluk seviyeleri belirlenmiştir.

Lei ve ark. (2018) tarafından yapılan çalışmada, dijital görüntü işleme ile birleştirilen İHA teknolojileri yardımıyla manuel görsel incelemenin dezavantajlarının üstesinden gelmek için köprü

yapılarının çatlak incelemesi yapılmıştır. Bununla birlikte, dengesiz doğal ışık, İHA donanımının ürettiği sesler, yol yüzeyindeki noktalar ve İHA titreşimi gibi çevresel etkiler nedeniyle, İHA'lar tarafından toplanan görüntülerin genellikle bulanık ve nispeten düşük kontrastlı olduğu belirtilmiş ve bu tür toplanan görüntülerin işlenmesinde, Canny algoritması, Prewitt algoritması ve Sobel algoritması gibi geleneksel kenar algılama algoritmaları, zayıf anti-aminoiz yeteneklerinden dolayı düşük algılama doğruluğuna sahip olduğu ortaya konulmuştur. Bu temel sorunları ele almak için çatlak merkezi noktaya dayalı yeni bir çatlak tespit yöntemi, yani çatlak merkezi nokta yöntemi (CCPM) önerilmiştir. Az miktarda görüntü ile yeni yöntem, toplanan görüntülerdeki çatlakları hızlı ve doğru bir şekilde belirleyebilmiştir. Geleneksel kenar algılama yöntemleri ve K-ortalımalı kümeleme yöntemiyle karşılaştırıldığında, Önerilen CCPM yönteminin daha iyi bir uygulanabilirliğe sahip olduğu ortaya konulmuştur.

Yoshitake ve ark. (2018) tarafından yapılan çalışmada, tünel kaplama betonunun yüzey kalitesini ölçmek için yan duvarlardaki beton çukurları (yüzey hava boşlukları) için bir ölçüm ve sayısallaştırma sistemi geliştirilmiştir. Bu doğrultuda ticari bir dijital sabit kamera ile çekilmiş renkli görüntülerin kırmızı, yeşil, mavi değerleri kullanılarak değerlendirme işlemi gerçekleştirilmiştir. Geliştirilen sistemin, kullanan görüntü analizlerinden daha yüksek doğruluğa sahip olduğunu, yüzey çukur ve deliklerinin neredeyse ayrıntılı bir görsel incelemeye eşit doğrulukla tahmin edebildiğini göstermiştir. Sonuçlar, renkli görüntü analizinde küçük deliklerin (<1 mm) bile tespit edilebileceğini teyit ederken, bu tür deliklerin ayrıntılı görsel araştırmada neredeyse hiç tespit edilemediğini ortaya koymuştur. Ek olarak, renkli görüntü analizinin, beton bir yüzeye rastgele dağılmış çok sayıda yüzey boşluklarının alanlarının hesaplamalarını iyileştirdiği de tespit edilmiştir. Görüntü analizi kullanan temel testler, beton formun negatif açısının artması ve betonun işlenebilirliğinin azalması ile yüzey deliklerinin yaygınlığının arttığını da göstermiştir. Önerilen sistemin, görünür ve görünmez yüzey deliklere sahip beton bir yüzeyin sayısallaştırarak değerlendirmesinde uygulanabilir olduğu ortaya konulmuştur. Sonuçların, geliştirilen renkli görüntü analizinin, yüzey beton deliklerin makul ve uygun bir şekilde değerlendirilmesine katkıda bulunabileceğini ve çok fazla insan kaynağı gerektiren ve uzun bir inceleme süresine sahip ayrıntılı bir araştırmanın yerini alabileceğini göstermiştir.

Karaaslan ve ark. (2018) tarafından yapılan çalışma, köprü sahipleri için alt yapı denetimi, bakım, yönetim uygulaması ve güvenliğe önemli katkılar sunan akıllı, insan merkezli bir yöntem oluşturmayı amaçlamaktadır. Örneğin bir köprü denetçisi, bir öge üzerinde gördüğü, boyut bilgisini mevcut durumuyla birlikte gerçek zamanlı olarak göstermesi; giyilebilir bir holografik kulaklık cihazına entegre edilebilen akıllı bir karışık gerçeklik (MR) yapı iskelesi geliştirmek suretiyle sağlanmıştır. Bu durumdan yola çıkılarak çatlak gibi belirli bir kusurun söz konusu sistematik olarak analiz edilebileceği ortaya konulmuştur. Bu tür sistemlerin, denetçinin hata ölçümü, durum değerlendirmesi ve veri işleme gibi temel görevlerini yönetim sistemlerine hızlandırarak alt yapı denetimlerinin zamanını ve maliyetini potansiyel olarak azaltabileceği belirtilmiştir. İnsan

merkezli yapay zekânın (AI), denetçinin daha ölçülü ve objektif verileri toplamasına yardımcı olurken profesyonel muhakemesini de artırdığı ifade edilmiştir. Bu çalışmada yapılan değerlendirme sırasında insan denetimiyle etkileşime giren, dikkat yönlendirmeli yarı denetimli DÖ'nün karma gerçeklik teknolojisine uygulanmasına ilişkin açıklanan sistemi ve ilgili metodolojileri ayrıntılı olarak belirtilmiştir. Sonuç olarak denetleyici ve yapay zekânın görsel değerlendirme için iş birliği içerisinde çalışabileceği ortaya konulmuştur.

Kang ve ark. (2018) tarafından yapılan çalışmada, tekil binaların işlevselliğini sınıflandırmak için (ofis binası, kilise, konut, garaj, endüstri yapısı vb.) genel bir çerçeve önerilmiştir. Önerilen yöntem CNN yapılarını kullanarak uzaktan algılamaya ek olarak Google Street View gibi sokak görsellerinden yapıları sınıflandırma esasına dayanmaktadır. Tekil binaları maskeleyerek (etiketlemek) ve ilgili sokak görüntülerini ilişkilendirmek için coğrafi bilgiler kullanılmıştır. CNN'leri eğitmek ve değerlendirmek için kullanılan bir kıyaslama veri seti oluşturulmuştur. Ayrıca yöntem, Kanada ve ABD'deki çeşitli şehirlerin hem bölge hem de şehir ölçeğinde bina sınıflandırma haritalarını oluşturmak için uygulanmıştır. Yöntemin uygulanması neticesinde her iki şehirde de biner yapı dikkate alınmış ve söz konusu yapıların sınıflandırılmasında Boston şehrinde %55, Toronto şehrinde ise %75 doğruluğa erişilmiştir.

Zhank ve ark. (2019) tarafından yapılan çalışmada, kolonlar ve duvarlar dâhil olmak üzere yapısal öğeleri otomatik olarak tanımlamak için yenilikçi bir gri seviye histogramı kullanarak istatistiksel özellik tabanlı nesne algılama yöntemi önerilmiştir. Bu yöntem ile bir RGB görüntüsü (yani görüntü renkleri kırmızı, yeşil ve mavi ışığın bir karışımıdır) gri tonlamalı bir görüntüye dönüştürülmüş, ardından Prewitt operatörü ve Hough dönüşümü kullanılarak dikey sınır çizgileri tespit edilmiştir. Algılanan çizgilerle görüntü birkaç alt bölgeye ayrılmıştır. Ardından, her bir alt bölgenin üç GLH istatistiksel parametresi (varyans, çarpıklık ve basıklık) hesaplanmıştır. Son olarak, bir alt bölgedeki bir kolon veya bir duvar, alt bölgenin bu özellikleri önceden tanımlanmış kriterleri ile örtüşmesi halinde söz konusu elemanlar sistem tarafından algılanabilmiştir. Bu yöntem, kolon ve duvar görüntüleri için algılama hassasiyeti ve geri çağırma testiyle doğrulanmıştır. Sonuçlar, çeşitli yüzey işlemleri veya saptırılmış şekillerle yapısal elemanların tespit edilmesinde önerilen yöntemin yüksek doğruluğunu göstermiştir.

Perez ve ark. (2019) tarafından yapılan çalışmada, görüntülerden küf, bozulma ve leke gibi temel bina kusurlarının otomatik olarak algılanmasına ve yerinin belirlenmesine yönelik CNN uygulanmasını değerlendirmek amaçlanmıştır. Önerilen model, VGG-16'nın önceden eğitilmiş CNN sınıflandırıcısına dayandırılmıştır. Nesne yerelleştirmesi için sınıf etkinleştirme haritaları ile eşlemesi sağlanmış ve daha sonra ResNet-50 ve Inception modelleriyle karşılaştırılmıştır. Gerçek hayattaki uygulamalarda modelin zorlukları ve sınırlamaları tespit edilmiştir. Önerilen modelin tutarlı olduğu ve bina kusurlarını doğru bir şekilde tespit edebildiği kanıtlanmıştır. Önerilen yaklaşımın, mobil

cihazlar ve İHA kullanılarak gerçek zamanlı olarak kusurların ve binaların hasarlarının otomatik olarak tespitini yapabilmek için geliştirileceği belirtilmiştir.

Vashpanov ve ark. (2019) tarafından yapılan çalışmada, yakın mesafeli fotoğraflamaya dayalı yüksek çözünürlüklü bir kamera ile elde edilen çatlak beton yüzeyin 8 bit RGB görüntüsü ve bir optik mikroskop kullanarak, çatlağın geometrik parametrelerini tahmin etmek için kullanılmıştır. Çatlak genişliği, derinliği ve morfolojisi gibi parametreler görüntünün piksel yoğunluğu dağılımı ile belirlenmiştir. Tahmin için görüntü, çatlağın geometrik parametrelerini geliştirmek için 16 bitlik gri ölçeğe dönüştürülmüş ve ardından, geliştirilmiş görüntüye dayalı olarak yoğunluk dağılımını derinlik ve genişlik ile ilişkilendiren matematiksel bir ilişki türetilmiştir. Bu ilişki, deneylerde kullanılan çatlak örnekleri için sırasıyla $\pm \%10$ ve $\pm \%15$ doğrulukla genişlik ve derinliğin tahmin edilmesini sağlamıştır. Farklı aydınlatma yönleri ile elde edilen çatlakların görüntüleri ile 8 bitlik RGB görüntüsü sentezlenmesi durumunda doğruluğun daha da iyileştirilebileceğinin beklendiği ortaya konulmuştur.

Rezai ve ark. (2020) tarafından yapılan DÖ ve Dijital Görüntü Korelasyon Ölçümlerini Kullanarak Çatlak Bölütlemelerin Karşılaştırılması adlı çalışmada taş duvarlar üzerine yapılan çalışmadan elde edilen gri tonlama görüntüleri üzerine çatlak bölütleme için kullanılan 2 yaklaşımın performansı mukayese edilmiştir. Bu bağlamda DÖ yaklaşımından elde edilen verilerin eşik yönteminden elde edilen verilerden daha yüksek doğruluk gösterdiği saptanmıştır (Sırasıyla %47 ve %34).

Bingöl ve ark. (2020) yaptıkları çalışmada, DÖ ve görüntü işlemeye ilişkin prosedürleri uygulamak suretiyle mimari tasarımın ilk evrelerinde, mimarlara taşıyıcı sistem elemanlarının boyutlandırılması ve konumlandırılması işlemlerinde yardımcı olması açısından bir düzensizlik kontrol asistanı teşkil etmişlerdir. Bu çalışma ile tasarlanan projeler için zaman kaybı olmadan yüksek doğruluk ve konumlandırma ile projelerin tanzim edilmesi hedeflenmiştir.

Dao ve ark. (2020) tarafından yapılan çalışmada, matern 32, matern 52, üstel, kare üstel ve rasyonel kuadratik ve bir YSA ile 5 farklı çekirdekli Gaussian process regression (GPR) adlı iki yapay zekâ tekniğinin duyarlılığını ve sağlamlığını yüksek performanslı beton (HPC) basınç dayanımının tahmini için bir Monte Carlo simülasyonu analiz etmeyi amaçlamışlardır. Bu doğrultuda, sekizi girdi (çimento, yüksek fırın cürufu, uçucu kül, su, süper plastikleştirici, iri agregalar, ince agregalar ve beton yaşı) parametresi ve bir tanesi çıktı parametresi olmak üzere eğitim ve test veri setlerini oluşturmak için basınç dayanımı dâhil 1030 numune toplanmıştır. Önerilen yapay zekâ modelleri; belirleme katsayısı (R^2), kök ortalama kare hata ve ortalama mutlak hata olmak üzere birkaç standart kriter kullanılarak doğrulanmıştır. Modellerin hassasiyetini ve tutarlılığını analiz etmek için 500 devir ile Monte Carlo simülasyonları yapılmıştır. Sonuçlar, matern 32 çekirdek işlevini kullanan GPR'nin diğerlerinden daha iyi performans sergilediğini göstermiştir. Bu sonuçlara ilave olarak, duyarlılık analizi ile HPC basınç dayanımını tahmin etmek için çimento içeriği ve HPC'nin test yaşının en hassas

ve önemli faktörler olduğu kanıtlanmıştır. Kısacası, bu çalışma HPC basınç dayanımının doğru ve hızlı tahmini için uygun yapay zekâ modellerinin ve uygun girdi parametrelerinin seçilmesine yardımcı olabilecek bir çalışma olarak dikkat çekmektedir.

Kim ve Cho (2020) tarafından yapılan çalışmada, segmentasyon için geliştirilmiş son teknoloji ürünü bir DÖ çerçevesi olan Mask R-CNN'e dayalı çoklu somut hasarların otomatik olarak tespit edilmesi için bir teknik önerilmiştir. Üç aşamadan (bölge önerisi, sınıflandırma ve segmentasyon) oluşan Mask R-CNN'nin yapısı, çoklu beton hasar tespiti için optimize edilmiştir. Optimize edilmiş Mask R-CNN; çatlaklar, çiçeklenme, donatı etkisi ve dökülme dâhil olmak üzere 765 beton görüntüsü ile eğitilmiştir. Eğitimli Mask R-CNN'nin performansı, çevresel nesnelerin yanı sıra hasar içeren 25 gerçek test görüntüsü ile değerlendirilmiştir. Yerleştirme ve segmentasyon performansını ölçmek için iki tür ölçüm önerilmiştir. Ortalama olarak, yerleştirme için %90,41 hassasiyet ve %90,81 geri çağırma elde edilmiş ve segmentasyon için %87,58 geri çağırma elde edilmiş, bu da eğitimli Mask R-CNN'nin mükemmel bir şekilde uygulanabilirliğini göstermiştir. Bu çalışma ayrıca, genel nesne algılama amaçları için optimize edilmiş Mask R-CNN mimarisinin uzun ve ince çatlak şekillerinin, donatı etkisinin daha sonraki araştırmalarda çiçeklenmeyi tespit etmek için değiştirilebileceğini açıklayarak test sonuçlarını niteliksel olarak ortaya koymuştur.

Karaçay (2021) tarafından yapılan çalışmada, betonarme yapılarda oluşan çatlakların belirlenmesi amacıyla görüntü işleme ve DÖ uygulamalarının kullanımına ilişkin konular araştırılmıştır. Bu doğrultuda içerisinde çatlak var olan ve olmayan betonarme yapıların bulunduğu görsellerden oluşan 3 farklı veri seti teşkil edilmiştir. DÖ algoritmalarının eğitilmesi ve test edilmesi amacıyla oluşturulan veri setlerinin farklı kategorizasyonları kullanılarak elde edilen neticeler üzerinden değerlendirmeler yapılmıştır. Söz konusu çalışmada görüntü bölütleme işlemlerini gerçekleştirmesi amacıyla oluşturulmuş olan U-Net'ten faydalanılmıştır. Kullanılan algoritma ile betonarme yapılardaki çatlaklar yüksek hassasiyet ile tespit edilebilmiş ki bu da U-Net mimarisinin söz konusu alanda kullanımının mümkün olduğunu göstermiştir.

2.3. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemlerini ve Yapay Zekâyı Bütünleştiren Çalışmalara İlişkin Kaynak Araştırması

Teknolojide yaşanan gelişmeler ve yapay zekâ disiplindeki ilerlemeler, araştırmacıları hızlı sismik değerlendirme alanında farklı arayışlara sürüklemiş ve bu doğrultuda DÖ, MÖ oldukça yaygın bir şekilde kullanılmaya başlamıştır. Bu çalışmaların öncülerinden olan Güler (2005) tarafından yapılmış araştırmada, YSA kullanılmak suretiyle mevcut binaların dataları üzerinden hasar tespiti yapabilen bir metot geliştirilmiştir. Herhangi bir yönetmelikte yer alan detaylı analizlere başvurulmadan birçok girdi parametresinin kullanıldığı çalışmada dikkate değer neticeler elde edilmiştir. Lautour ve Omenzetter (2009) tarafından yapılan çalışmada ise hasar indeks değerleri

kullanılarak sonlu elemanlar yöntemi vasıtasıyla betonarme çerçeve elemanlarının hasarlarına ilişkin öngörülerde bulunulmuştur. Baltacıoğlu ve ark. (2010) tarafından yapılan çalışmada deprem tecrübesi yaşamış mevcut betonarme bir binanın hasara ilişkin dataları dikkate alınarak söz konusu hasarların tespiti amacıyla YSA'yı kullanan bir yöntem geliştirilmiştir. Arslan ve ark. (2015) tarafından icra edilmiş bir diğer çalışmada ise YSA temelli, mevcut betonarme binaların hızlı sismik değerlendirilmesinde kullanılabilecek bir metot ileri sürülmüştür. Bu bağlamda DBYBHY-2007 uyarınca deprem performansları belirlenmiş olan betonarme binalar kullanılmak suretiyle geliştirilen YSA temelli yöntemin kalibrasyonu sağlanmıştır. 66 adet betonarme binanın kullanıldığı çalışmada %64,26 doğruluk yüzdesi ile söz konusu binaların deprem performansları tespit edilmiştir. Morfidis ve Kostinakis (2018) tarafından yapılan çalışmada, zaman tanım alanında doğrusal olmayan hesap metodu ile maksimum kat deplasmanları hesaplanmış ve bu değerleri dikkate alan YSA tabanlı bir model geliştirilerek oluşan deplasmanlara ilişkin tahminler yapılmıştır.

Sextos ve ark. (2008) tarafından yapılan çalışmada 1999 yılında Düzce ilinde yaşanan deprem sonrasında hasar görmüş binaların dataları kullanılmak suretiyle bir veri seti teşkil edilmiştir. Tanzim edilen bu veri seti kullanılarak söz konusu ilin bölgesel şartları da dikkate alınarak yeni bir hızlı sismik değerlendirme metodu geliştirilmiş ve bahse konu binaların hasar seviyeleri göz önünde bulundurularak risk önceliklendirme çalışması yapılmıştır.

Koyuncu (2009) tarafından yapılan yüksek lisans tez çalışmasında, betonarme binaların performanslarının belirlenmesinde ciddi önem taşıyan 23 farklı karakteristik özelliği bünyesinde barındıran ve kat adetleri 4-10 arasında değişiklik gösteren 66 adet betonarme bina için bir veri seti oluşturulmuştur. Söz konusu binaların DBYBHY-2007 uyarınca performans seviyeleri belirlenmiştir. Geliştirilen algoritma ile hem zamandan hem de maliyetten tasarruf edilerek %80 doğruluk oranı ile bahse konu binaların performans seviyeleri belirlenmiştir.

Dristos ve ark. (2013) tarafından yapılan çalışmada YSA ve bulanık mantık uygulamaları kullanılmak suretiyle yeni bir hızlı değerlendirme metodu geliştirilmiştir. Araştırma için önerilen yöntemin kalibrasyonunda geçmiş depremlerde hasar görmüş yapıların kayıtları kullanılmıştır. Geliştirilen yöntem ile mevcut hasar kayıtlarının mukayese edilmesi neticesinde önemli doğruluk yüzdeleri ile tahmin yapılabildiği ifade edilmiştir.

Işık ve ark. (2018) tarafından yapılan çalışmada, geliştirilen hızlı sismik değerlendirme yönteminde dikkate alınan parametrelerin tamamını girdi datası olarak kullanabilen bir veri tabanı teşkil edilmiştir. Çalışma kapsamında 1 ile 7 katlı betonarme binaların cephe görselleri toplanmış ve söz konusu görseller veri tabanına işlenmiştir. Ayrıca veri seti içerisinde yer alan her bir betonarme bina için risk öncelik kartı da düzenlenmiştir. Diğer taraftan, binalara eklenen QR (quick response) uygulaması vasıtasıyla kullanıcıların, tabletleri ve akıllı telefonları ile söz konusu binaların risk durumlarına ilişkin bilgilere kolaylıkla erişebilmeleri sağlanmıştır.

Nahata ve ark. (2018) tarafından yapılan çalışmada, CNN tabanlı bir otonom hasar tespit modeli önerilmiştir. 1000'den fazla eğitim ve 200'ü test olmak üzere 1200'den fazla farklı bina görüntüsü, maruz kalınan hasarın boyutuna göre 4 kategoride sınıflandırılmıştır. Kategoriler: hasarsız, az hasar, büyük hasar ve çökme olarak ifade edilmiştir. Eğitimli ağ, farklı öğrenme oranlarına sahip çeşitli algoritmaların uygulanmasıyla test edilmiştir. En optimum sonuçlar 10^{-5} öğrenme oranı ile (Visual Geometry Group 16 (VGG-16) transfer öğrenme modelinin uygulanmasından elde edilmiştir, ki bu modelde eğitim doğruluğu %97,85 ve doğrulama doğruluğu da %89,38'e kadar çıkmıştır. Sonuç olarak geliştirilen modelin, deprem anında gerçek zamanlı uygulamaya konulabileceği kanıtlanmıştır.

Ali ve ark. (2018) tarafından yapılan çalışmada, Faster Region Convolutional Neural Networks (Daha Hızlı Bölge Evrişimli Sinir Ağları) (FRCNN) Yöntemi ile bir duvar yapısı için bir hasar tespit algoritması önerilmiştir. Duvar yapısında hasar tespit sistemini eğitmek için etiketli bir veri seti oluşturulmuş ve önerilen sistemin iyi performans gösterdiğini ve hesaplama hızıyla yığma yapılardaki hasarı tespit etmek için kullanılabilmesi ifade edilmiştir.

Mohamad ve ark. (2019) tarafından yapılan çalışmada, coğrafi bilgi sistemi çerçevesinde RVS Yöntemi kullanılarak binaların belirlenmesi, değerlendirilmesi ve hesaplanan zafiyetlerin ortaya konulması amaçlanmıştır. Yapılan çalışmanın sonuçları, 245 binadan 21 bina için hasar seviyesinin sırasıyla 3. derece, 11 binanın 2. derece, diğer binaların 1. derece hasarlı veya ağır hasarlı, orta dereceli veya az hasarlı olduğunu ortaya koymuştur. Önerilen yöntem ile binaların hasar seviyeleri tespit edildikten sonra, gelecekte yaşanacak depremler nedeniyle yapıların daha fazla zarar görmesini önlemek için erken bir önlem alınmasını sağlayabileceği ortaya konulmuştur.

Zhang ve ark. (2019) tarafından yapılan çalışmada, bir veri madenciliği tekniği geliştirilerek bölgesel ölçekte binaların sismik hassasiyetini değerlendirmek için SVM kullanılmıştır. Özellikle, binaların spektral verimi ve kapasite eğrilerinin nihai noktaları açısından makro ölçekli sismik kırılma hızının hızlı bir şekilde değerlendirilmesi için bir SVM modeli geliştirilmiştir. Önerilen SVM modelini test etmek için biri 11 bina özelliğini içeren, diğeri 20 bina özelliğini içeren iki vaka çalışması kullanılmıştır. Sonuçlar; eğitim veri seti 400 örnek içerdiğinde, bireysel bir binanın spektral verimi ve nihai noktaları açısından sismik hassasiyeti %64 doğrulukla, eğitim veri seti 4400 örnek içerdiğinde ise %74'e yükselen ortalama doğrulukla tahmin edilebileceğini göstermiştir. Önerilen tekniğin binaların konumlarına dayalı talep eğrileriyle birleştirilmesi, bölgesel ölçekte hızlı ve güvenilir sismik risk değerlendirmesine olanak sağlayacağı ve karmaşık hesaplama modelleri yerine yalnızca temel bina özelliklerinin kullanılabilmesi belirtilmiştir.

Yu ve ark. (2019) tarafından yapılan çalışmada, inşaat mühendisliğini güçlendirebilmek için yapay zekânın nasıl yardımcı etmen olabileceğini ortaya koyabilmek adına yapılan iki durum çalışması icra edilmiştir. İlk durumda, şehir ölçeğinde bina bilgi modellemesi için MÖ destekli bir çerçeve olan BRAILS önerilmiştir. Önerilen yöntemde, binaların görsel bilgilerini uydu ve sokak

görüntülerinden çıkarmak için DÖ tekniği kullanılmıştır. Ayrıca, meta veri oluşturmadaki uzamsal kalıpları keşfetmek için yeni bir MÖ tabanlı istatistiksel araç olan SURF önerilmiştir. İkinci durumda ise, yumuşak katlı binaların sınıflandırılması işlemine odaklanılmıştır. Bu görev için, bölgesel ölçekte sokak görüntülerinden yumuşak katlı binaları tanımlamak amacıyla otomatik DÖ'ye dayalı bir prosedür önerilmiştir. Ayrıca, büyük ölçekli bir bina görüntüsü veri tabanı ve yeni bir veri tabanı girişlerini etkili bir şekilde açıklayan yarı otomatik bir görüntü etiketleme yaklaşımı oluşturulmuştur. Kapsamlı hesaplama deneyleri sayesinde önerilen yöntemin etkinliği gösterilmiştir.

Harirchian ve Lahmer (2020) yaptıkları çalışmada betonarme binaların depreme karşı dayanıklılığını etkileyen geometrik özellikleri (kat adedi, kolon alanı, toplam zemin alanı vb.) dikkate alarak YSA vasıtasıyla betonarme binaların hasar seviyesini doğru şekilde tahmin edebilmeyi amaçlamışlardır. Bu bağlamda Haiti depreminde hasar görmüş 145 binanın verisi kullanılarak çok katmanlı YSA eğitilmiş ve optimize edilmiştir. Yapısal hasarları sınıflandırmak için kullanılan bu yaklaşımın pratik ve etkili olduğu ve %55'lik bir doğruluk oranı ile yapıların hasarlarının tespit edilebildiği ortaya konulmuştur.

Harirchian ve Lahmer (2020) yaptıkları çalışmada mevcut binaların ayrıntılı değerlendirmeye tabi tutulması önceliğini belirlemek için aralıklı tip-2 bulanık mantık sistemine dayalı yeni bir RVS metodolojisi önermeyi amaçlamıştır. Önerilen yöntemde, tek bir çıktı değişkeni ile girdiler olarak kat sayısı, bina yaşı, plan düzensizliği, düşeyde düzensizlik, bina kalitesi ve tepe-zemin hızı dikkate alınarak bir binanın hasar indeksi açısından kırılabilirliği tahmin edilmiştir. Önerilen yöntemin uygulanabilirliği, Türkiye'deki Bingöl ve Düzce depremlerinden alınan betonarme binaların deprem sonrası hasar veri tabanı kullanılarak araştırılmıştır. Bingöl ilinde deprem sonrası binalarda gözlemlenen hasarlar, hasar seviyelerine göre; %21,4 hasarsız, %32,1 az hasarlı, %25 orta hasarlı, %17,9 ciddi hasarlı ve %3,6 çökme seviyesinde iken önerilen metotta sırasıyla bu yüzdeler; %14,3, %21,4, %32,1, %25, %7,1; Düzce ilinde ise deprem sonrası binalarda gözlemlenen hasarlar, hasar seviyelerine göre; %12,8 hasarsız, %30,9 az hasarlı, %31,2 orta hasarlı, %11,9 ciddi hasarlı ve %13,2 çökme seviyesinde iken önerilen metotta sırasıyla bu yüzdeler; %8,2, %22,5, %35,6, %19,2, %14,5 olarak tespit edilmiştir.

Valentijn ve ark. (2020) otomatik bina hasar değerlendirmesi için CNN'lerin kullanılabilirliği adlı çalışmalarında; uzaktan algılanan görüntüler ile bina hasarlarının hızlı ve kapsamlı bir şekilde değerlendirilmesine CNN'lerin olanak sağladığını ortaya koymuşlardır. Bu bağlamda 13 farklı afet (sel, tsunami, volkanik patlama vb.) sonucu oluşmuş görüntülerin üzerinde çalışmalar yürütmüşlerdir. Yüksek çözünürlüklü bir uydu yardımı ile afetlerde hasar görmüş olan 175.289 adet binanın hasar sınıflarını ifade eden parametreler (kırmızı, yeşil ve mavi) ile söz konusu yapılar etiketlenmiştir. Sonuç olarak etiketleme işlemi yapılmayan bir binanın hasar seviyesinin bahsi geçen yöntemle etkili bir şekilde belirlenebileceği kanıtlanmıştır.

Harirchian ve ark. (2020) yaptıkları “Mevcut Binaların Deprem Tehlikesinin Hızlı Değerlendirilmesi İçin Destek Vektör Makine Modelinin Uygulanması” adlı çalışmada 1999 yılında Düzce’de yaşanan depremde hasar görmüş binaları 22 farklı performans değişkenini dikkate alarak eğitmiş ve optimize etmiştir. Yapılan çalışma neticesinde ise %52 oranında bir doğruluk ile söz konusu binaların hasar seviyeleri tespit edilmiştir.

Harirchian ve ark. (2020) tarafından yapılan çalışmada, aralıklı tip-2 bulanık mantık sistemi kullanılarak binaların depreme karşı hızlı görsel tehlike güvenlik değerlendirilmesi için yeni bir yöntem tanıtılmaktadır. Ayrıca önerilen yöntemde, binanın önemi ve maruziyeti ile ilgili faktörler de göz önünde bulundurularak binanın deprem riskinin değerlendirilmesine olanak sağlandığı belirtilmiştir. Diğer taraftan, önerilen yöntemin bir akıllı telefon uygulaması prototipi tanıtılmıştır. Söz konusu yöntemin uygulanabilirliği için iki vaka çalışması seçilmiş ve analiz sonuçları önerilen yöntemin etkinliğini ortaya koymuştur.

Harirchian ve ark. (2020) tarafından yapılan çalışmada, FEMA-154, IITK-GGSDMA (Hindistan Metodu) ve EMPI (Türkiye Metodu) gibi yaygın RVS yöntemlerine genel bir bakış sunulmuştur. Söz konusu çalışmanın doğruluğunu ve geçerliliğinin incelemek için, 1 Mayıs 2003 depreminden sonra Türkiye'nin Bingöl bölgesindeki bir sokak araştırmasında betonarme binaların değerlendirilmesi ile gözlenen hasar arasında pratik bir karşılaştırma yapılmıştır. Sonuçların, ön hasar tahmini için RVS yöntemlerinin uygulanmasının hayati bir araç olduğunu gösterdiği ifade edilmiştir. Ayrıca karşılaştırmalı analiz sonucunda FEMA P-154'ün hasar durumlarını olduğundan fazla tahmin ettiğini ve ekonomik olarak uygun olmayan bir değerlendirme oluşturduğunu, EMPI ve IITK-GGSDMA'nın ise sırasıyla daha doğru ve pratik tahmin sağladığını göstermiştir.

Harirchian ve ark. (2020) tarafından yapılan çalışmada, hasar sınıflandırma tekniği üzerinde yoğunlaşmış ve bir SVM modeli ile hasar tahmininde MÖ yönteminin etkinliği araştırılmıştır. Önerilen MÖ modeli, Ekvador, Haiti, Nepal ve Güney Kore olmak üzere dört farklı depremden gelen hasar verileri üzerinde ayrı ayrı eğitilmiş ve test edilmiştir. Her veri kümesi, değişen sayıda girdi verisinden ve binaların geometrik durumlarına ilişkin 8 farklı parametreden oluşmaktadır. Çalışma ve sonuçlara dayalı olarak, önerilen MÖ modeli, verilen girdi verilerini ait olduğu sınıflara uygun olarak sınıflandırmış (hafif, orta, ciddi ve çökme hasarı olarak sınıflandırma yapılmıştır.) ve binaların tehlike güvenlik değerlendirmesi performansını belirlemiştir.

Harirchian ve ark. (2020) yaptıkları çalışmada istatistikî veriler ve MÖ (optimize edilmiş çok katmanlı sinir ağları) yardımıyla mevcut binaların hasarlarını belirlemek için yaklaşımlar önermişlerdir. Bu doğrultuda YSA kullanarak betonarme binaların hasar seviyelerini doğru bir şekilde tahmin edebilmek için 6 bina performans değişkeni (kat adedi, normalleştirilmiş fazlalık puanı, yumuşak kat endeksi, çıkma oranı, minimum normalleştirilmiş yanal mukavemet endeksi, minimum normalleştirilmiş yanal sertlik endeksi) kullanmışlardır. Bu bağlamda Düzce depreminde hasar görmüş 484 binanın verisi kullanılarak çok katmanlı YSA eğitilmiş ve optimize edilmiştir.

Sonuç olarak önerilen yaklaşımın betonarme binaların hasarlarının belirlenmesi için etkili ve kullanılabilir bir yöntem olduğu kanıtlanmıştır.

Yu ve ark. (2020) tarafından yapılan çalışmada, bölgesel ölçekte sokak görünümü görüntülerinden yumuşak katlı binaları tanımlamak için DÖ tekniklerine dayanan otomatik bir prosedür tasarlanmıştır. Bu doğrultuda, DÖ modelini geliştirmek için çok sayıda bina görüntüsü içeren bir veri tabanı ve yeni veri tabanı girişlerine etkin bir şekilde açıklama ekleyen yarı otomatik bir görüntü etiketleme yaklaşımı geliştirilmiştir. Ayrıca, önerilen prosedürün etkinliğini incelemek ve otomatikleştirilmiş yumuşak katlı bina tanımlamasına ilişkin öngörüler elde etmek için kapsamlı hesaplama deneyleri gerçekleştirilmiştir.

Gonzalez ve ark. (2020) tarafından yapılan çalışmada, bir binanın yapısal tipolojisini tanımlayan nitelikler olan yapı malzemelerini ve yanal yük dirençli sistem türlerini otomatik olarak algılamak için bir CNN kullanma potansiyelini araştırmak için Medellin'in kentsel bölgesinde sokak seviyesinde elde edilen yaklaşık 10.000 fotoğraftan oluşan manuel olarak açıklanan bir veri seti kullanılarak bir model oluşturulmuştur. Geliştirilen bu modelin sonuçları, depremde hasar görme olasılığı en yüksek binalar olan sünek olmayan binaları tanımlarken %93 hassasiyet ve %95 geri çağırma elde etmiştir. Birçok görsel ipucunun fiziksel olarak gizlenmiş olması sebebiyle ince taneli malzemelerin tipolojisini belirlemenin zor olduğu aktarılmış, ancak önerilen modelin uzman seviyesindeki performanslarla eşleşerek en yaygın üç bina tipolojisinde %85 geri çağırma ve %60 ile %82 arasında değişen doğruluk puanları elde ettiği belirtilmiştir ki bu da Medellin'deki toplam bina nüfusunun %91'ini oluşturduğu ifade edilmiştir.

Wang ve ark. (2021) tarafından yapılan çalışmada, bina verileri toplanmak suretiyle bölgesel tehlike analizi icra edilmiştir. Bu çerçevede, birçok kaynaktan (uydu ve sokak görüntüleri, vergi değerlendirme verisi vb.) farklı veri elde edilmiş ve bir şehirde yer alan her bir binanın anlamsal profilini oluşturmak için söz konusu veriler birleştirilmiştir. Bu işlem yapılırken bina bilgilerini sokak veya uydu görüntülerinden çıkarmak için DÖ tekniği kullanılmıştır. Veri kıtlığı sorununun üstesinden gelmek, belirsizliği ölçmek ve veri havuzunu zenginleştirmek için yeni bir veri madenciliği aracı geliştirilmiştir. Bu çerçevede, afet ve risk yönetimi planlaması ve simülasyonları oluşturmak amacıyla şehirlerin bina envanterlerinin de teşkil edilmiş olduğu belirtilmiştir.

Plata ve ark. (2021) tarafından yapılan çalışmada, çatı diyaframının esnekliğine (sert veya esnek) göre tek katlı takviyesiz yığma binaların sokak düzeyindeki görüntülerini sınıflandırmak için CNN'lerin potansiyeli araştırılmıştır. Söz konusu yığma binaların güvenlik açığı çalışmaları, afet riski değerlendirmeleri, afet yönetimi stratejileri vb. için kritik ve en yaygın bina tipolojisi olduğu ve nüfusun çoğunluğunun bu tür binalarda yaşadığı şehirlerde büyük önem taşıdığı ifade edilmiştir. Araştırma sonuçları, VGG-19'un 0,80 doğruluk, 0,88 hassasiyet ve 0,84 geri çağırma ile en iyi performansa sahip CNN mimarisi olduğunu göstermiştir.

Harirchian ve ark. (2021) tarafından yapılan çalışmada, 5 farklı MÖ tekniğinin sismik hassasiyet tahmini uygulamalarında etkinliği araştırılmıştır. Geliştirilen modellerin eğitilmesi ve test edilmesi için Ekvador (172 adet bina), Haiti (145 adet bina), Nepal (135 adet bina) ve Güney Kore’de (74 adet bina) meydana gelen dört farklı depremin hasar verileri kullanılmıştır. 8 farklı parametre (kuşatılmış kolon durumu, kolon alanları, perde alanları, dolgu duvar alanları, toplam taban alanı, bodrum kat durumu) denetimli bir MÖ ile değişkenler olarak uygulanmıştır. Bu çalışma kapsamında yapılan araştırmalar, MÖ teknikleri ile değerlendirilen sismik hassasiyet sınıflarının (hafif, orta, ciddi ve çökme hasarı olarak sınıflandırma yapılmıştır.) binalarda gözlemlenen gerçek hasar seviyelerine çok yakın olduğunu göstermiştir. Bu doğrultuda söz konusu parametreler; Ekvador deprem verileri için %68, Haiti deprem verileri için %66, Nepal deprem verileri için %71, Pohang deprem verileri için %64’e ulaşan doğruluk oranları ile tespit edilmiştir.

Harirchian ve ark. (2021) tarafından yapılan çalışmada, RVS çalışma alanını ilerletmede her bir SC (yapay zekâ ile hesaplama) tekniğinin temel faktörlerine, güçlü yönlerine ve uygulamalarına ışık tutmak için, güçlü SC teknikleri kullanan RVS’de en sık kullanılan ve yeni geliştirilen yenilikçi metodolojilerin kapsamlı bir literatür taraması sunulmuştur.

Harirchian ve ark. (2021) tarafından yapılan çalışmada, YSA kullanılmak suretiyle mevcut betonarme binaların sismik hasar görebilirliği, hâlihazırda var olan veri kümeleri ile test edilmek suretiyle araştırılmıştır. Bu amaçla, Nepal ve Ekvador depremlerinden hasar görmüş binaların iki farklı veri tabanı kullanılarak çok katmanlı bir algılayıcı (MLP) ağı eğitilmiş ve optimize edilmiştir. Sonuçlar, sismik hassasiyeti fazla olan binaların tespiti için önerilen yöntemin izlenebileceği ve farklı bölgelerdeki diğer verilere uygulanabileceği ve dolayısı ile yapısal hasara dayalı gerçek hasar derecesini sınıflandırmak için seçilen YSA yaklaşımının uygulanabilirliğini ve etkinliğini göstermiştir. Ayrıca, önerilen yöntemeye dayalı olarak veri toplama ve sismik kırılma dayanıklılığı değerlendirme amaçları için bir akıllı telefon uygulamasının prototipi ve uygulaması tanıtılmıştır.

Ünlü ve Kiriş (2022) tarafından yapılan çalışmada, yapay zekâ tabanlı sistemler beklenmedik afetler sonrasında sokak kamera sistemlerine entegre edilerek hasarlı veya yıkılmış binaları tespit etmek için test edilmiştir. Bu amaçla literatürde görüntü tanıma problemlerinde sıklıkla kullanılan VGG-16, VGG-19 ve NASNet Konvolüsyonel Sinir Ağı (KSA) modelleri hasarlı binaları tespit etmek için kullanılmıştır. Bu modelleri etkin bir şekilde uygulamak için önce tüm görüntüler K-ortalama kümeleme algoritması ile segmentlere ayrılmıştır. Daha sonra bu çalışmanın ilk aşaması için “hasarlı binalar” ve “normal” olarak etiketlenen segmentlere ayrılmış görüntüler sınıflandırılmış ve VGG-19 modeli test setinde %90 doğruluk oranı elde edilerek en başarılı model olduğu ifade edilmiştir. Ayrıca çalışmanın ikinci aşaması olarak, segmentlere ayrılmış görüntüleri “hasarlı binalar”, “az hasarlı binalar” ve “normal” olarak etiketleyerek çok sınıflı bir sınıflandırma problemi oluşturulmuştur. Test setinde en doğru sınıflandırma sonuçlarını elde etmek için aynı üç mimari

kullanılmıştır. VGG-19, VGG-16 ve NASNet mimarilerinin sırasıyla yaklaşık %70, %67 ve %62 doğruluk elde ettikleri ifade edilmiştir.

Kumari ve ark. (2022) tarafından yapılan çalışmada, farklı depremleri dikkate alan bir veri seti kullanılarak RVS'ye yönelik bilinen birkaç parametrik olmayan algoritma araştırılmıştır. Ayrıca, uygulanan yöntem binaların önemi ve maruziyeti ile ilgili faktörlere dayalı olarak söz konusu binaların sismik kırılma olasılığını inceleme olasılığını ortaya koymaktadır. Çalışma kapsamında; kat sayısı, toplam bina taban alanı, kolon kesit alanı, X ve Y doğrultularındaki betonarme duvar alanları, X ve Y doğrultularındaki dolgu duvar alanları ve kuşatılmış kolon durumları dikkate alınan parametrelerdir. Diğer taraftan, bu çalışmada Django üzerine kurulu web tabanlı bir uygulama geliştirilmiştir. Bahse konu arayüz, sismik güvenlik açığı araştırmasını gerçek zamanlı olarak kolaylaştırma fikriyle tasarlanmıştır. Önerilen yöntem iki vaka çalışması kullanılarak doğrulanmış ve elde edilen sonuçlar bahse konu yaklaşımın potansiyel verimliliğini göstermiştir. Bu doğrultuda söz konusu parametreler; Nepal deprem verileri için %71,40, Pohang deprem verileri için %57,14'e ulaşan doğruluk oranları ile tespit edilmiştir.

Bülbül ve ark. (2022) tarafından yapılan çalışmada, mevcut yapı stokunun büyük bir bölümünü oluşturan betonarme binalar için risk önceliklerini tahmin etmek amacıyla YSA tabanlı bir model geliştirilmiştir. Bu doğrultuda, Genetik Algoritma ile hibrit bir yapı kurularak ağ yapısındaki ağ parametreleri optimize edilmiştir. Sonuç olarak, önerilen YSA modelinin maksimum verimlilikle doğru tahminler yapabildiği ortaya konulmuştur. Önerilen YSA modeli ile Türkiye hızlı değerlendirme metodu (2013) kullanılarak performans puanı hesaplanan 329 betonarme binanın risk önceliklerini en başarılı şekilde tahmin edilmesi hedeflenmiştir. Ayrıca, bu makalede önerilen modelin ortaya koyduğu en başarılı genetik kullanan YSA'nın performans puanının hesaplanmasında başarılı sonuçlar ürettiği bir GA-ANN hibrit modeli gerçekleştirilmiştir. Ayrıca böyle bir problemin çözümünde daha verimli sonuçlar elde etmek için gerekli girdi parametreleri ve böyle bir YSA ağ yapısının kurulmasında kullanılması gereken parametreler optimize edilmiştir. Oluşturulan hibrit model doğrultusunda betonarme binaların risk önceliği %98 doğruluk oranı ile belirlenmiştir.

Wen ve ark. (2022) tarafından yapılan çalışmada, sınırlı bina bilgilerini kullanarak mevcut betonarme çerçeve binaların sismik tepki tahmini için bir yöntem geliştirmeyi amaçlamışlardır. Düşük ve orta yükseklikte toplam 162 tipik betonarme çerçeve bina tasarlanmış ve her bir binadaki her katın katlar arası ötelenmesi ve en yüksek kat ivmesi doğrusal olmayan zaman alanı analiz yöntemi ile 200 yer hareketi için hesaplanmıştır. Yer hareketi kayıtları ve girdi olarak kolay elde edilen 5 bina parametresi (sismik tasarım yoğunluğu, kat sayısı, kat yüksekliği, kolonlar arası düşey uzunluk, toplam enine uzunluk) ile bir CNN geliştirilmiştir. Çıktılar, verilen bina için her katın katlar arası ötelenme ve tepe kat ivmesi değerleridir. Bir girdi parametresinin fiziksel araçları göz önüne alınarak; kat sayısı, değiştirilmiş kayıp fonksiyonu ve değiştirilmiş değerlendirme fonksiyonu önermişlerdir. Geliştirilen ağ, hesaplanan veri seti ve değiştirilmiş kayıp fonksiyonu ile eğitilmiştir.

Eđitilen modelin (StruNet olarak adlandırılır) önceki alıřmalara kıyasla yer hareketlerini ve yapıların özelliklerini birlikte dikkate alabildiđi ifade edilmiřtir. Önerilen model, DÖ veri setinden bađımsız olan 4 farklı durum aracılıđıyla dođrulanmıřtır. Sonuçların önerilen yöntemin yeterli dođrulukta tahmin verileri sunduđu ve yüksek hesaplama verimliliđi gösterdiđi ortaya konulmuřtur.


Yukarıda 3 bölüm halinde özetlenen literatürden de anlaşılacađı üzere Türkiye’de ve dünyada betonarme binaların sismik açıdan hızlı deđerlendirilmesi konusunda ve yapay zekâ ve inřaat mühendisliđini bütünleřtiren alıřmalar hakkında yoğunlařıldıđı ve söz konusu alanlarda oldukça önemli birok akademik alıřmanın da icra edildiđi görölmektedir. Bununla beraber her ne kadar deprem öncesi hızlı sismik deđerlendirmeler, yapay zekâ alıřmalarını entegre eden DÖ’nün kullanıldıđı nesne algılamaya yönelik deprem öncesi ve sonrasındaki yapısal hasarların tespit edilebildiđi alıřmalar yapılmıř olsa da dođrudan bu tez alıřması kapsamında yapılmıř bütünleřik bir alıřma göze arpmamaktadır. Bu açıdan tez kapsamında bina cephe görselleri üzerinden taşıyıcı sistem ile ilgili 3 farklı parametrenin (ađır ıkma, bitiřik nizamlılık durumu ve eđimli arazi varlıđı durumu) varlıđı ya da yokluđu durumları tespit edileceđi için bu alıřma literatürde ilk kez yapılmıř olacaktır.

Diđer taraftan, güncel literatürün incelenmesi sonucunda önümüzdeki yıllarda ok sayıda veri seti üzerinden CNN kullanılarak deprem öncesi hızlı sismik deđerlendirme konusunda arařtırmaların yapılmaya bařlayacađını da göstermekte olup, yapılmıř olan bu tezin de ileride yapılacak olan alıřmalarda bir basamak görevi göreceđi de ařıkârdır. Ayrıca, tespit edilebildiđi kadarıyla bu tez alıřması DÖ’nün yapı mühendisliđinde kullanıldıđı ilk doktora tezi olma özelliđini de göstermektedir.

3. YAYGIN DEPREM HASARLARI VE DEPREM ÖNCESİ HIZLI DEĞERLENDİRME YÖNTEMLERİ

3.1. Deprem Hasarları ve Nedenleri

Türkiye’de nüfusun büyük çoğunluğu ciddi anlamda tehlike arz eden deprem bölgelerinde yaşamaktadır (Şekil 3.1). Buna paralel olarak da yapı stokumuzun önemli bir çoğunluğu deprem riski altında olup yıllardır ciddi büyüklükteki depremlere maruz kalmış ve önemli can ve mal kayıpları yaşanmıştır. Yaşanan kayıplar sadece kırsal bölgelerle sınırlı olmayıp, yapı stokunun büyük bölümü betonarme olan kentsel bölgelerde de (Erzincan 1939, Erzincan 1992, Kocaeli 1999, Van 2011, Elâzığ 2020, İzmir 2020 vb.) önemli maddi ve manevi kayıplar oluşmuştur. Özellikle orta büyüklükteki depremler, gelişmiş ülkelerde sıradan bir olay olarak atlatılırken, ülkemizde hala önemli doğal afetlerden biri olma özelliğini sürdürmektedir. Ayrıca mevcut yapı stokunun büyük çoğunluğu da olası bir depremle karşılaşma riski taşımaktadır. Ülkemizdeki mevcut betonarme yapı stokunun yaşanabilecek bir depreme karşı yetersiz kalacağı ve yapısal düzensizliklerin olası depremler için tehlike arz edeceği de bilinmektedir. Yapısal düzensizliklerin bulunduğu çok sayıda yapının genellikle yüksek katlı yapı olması, yapı yüksekliğinin de önemli bir parametre olduğunu göstermektedir.



Şekil 3.1. Türkiye deprem tehlike haritası (AFAD, 2022)

Büyük depremler ülkemizin çeşitli bölgelerinde belirli zaman aralıklarında gerçekleşmekte olup deprem yönetmelikleri de yaşanan bu acı deprem tecrübeleri neticesinde çeşitli değişiklikler ve revizyonlar yaşamaktadır. Genellikle deprem yönetmelikleri geçmiş depremlerde gözlenen uygulama ve tasarım hatalarına, hasarlı binalarda gözlenen göçme mekanizmalarından çıkarılan sonuçlara göre tekraren gözden geçirilmektedir. Depremler her ne kadar toplumsal anlamda ciddi bir kaos ortamının oluşmasına neden olsa da söz konusu alanda çalışan teknik uzmanlar (mühendisler, mimarlar vb.) için eşsiz bir deneysel ortam oluşmasına olanak sağlamaktadır. Yapı mühendisliği disiplinde;

hataların tespiti, tasnif edilmesi ve icra edilecek sonraki uygulamalarda önlenmesi ve yaşanabilecek bir depreme karşı proaktif önlemlerin alınması oldukça elzemdir. Alınacak önlemler neticesinde sonraki kuşakların güvenli ve deprem açısından kaygısız bir yaşam seviyesine erişeceği de göz ardı edilmemelidir. Bu açıdan deprem neticesinde meydana gelen hasarların ve olası sebeplerinin belirlenmesi oldukça önemli olmakla beraber bir zorunluluk olarak da görülmektedir. Ancak, depremlerde bütünüyle çökmüş olan yapıların hasar mekanizmalarının kavranabilmesinin kolay olmaması hasebiyle deprem sonrasında yapılan teknik araştırmalarda ve hasar tespitlerinde çoğunlukla orta ve ağır hasarlı yapılara ilişkin yoğun çalışmalar icra edilmektedir. Söz konusu yapılarda icra edilen tetkikler neticesinde, mühendislik hataları ve uygulamadan kaynaklı hatalar tespit edilerek söz konusu problemler için çeşitli çözümler üretilmeye çalışılmaktadır. Yapılan incelemeler neticesinde depremlerde, yapıların bütünüyle göçmesi veya ciddi hasara uğraması büyük çoğunlukla benzer kusurlardan kaynaklı olduğu ortaya konulmuştur. Bu hasar ve göçmelerin sebeplerini genel anlamda şu şekilde sıralanabilir:

- İnşa edilecek yapının yer seçiminde yapılan hata neticesinde sınırlama, devrilme yaşanması.
- Eğimli arazi üzerine binaların inşa edilmesi sonucu maruz kalacağı deprem etkisinin artması (Eğimli arazi sorunu).
- Jeolojik ve topoğrafik nedenlerden dolayı bazı durumlarda binanın zeminle birleştiği katta seviye farkları oluşması neticesinde binanın en alt katında yer alan kolon elemanları arasındaki yükseklik farklarına neden olarak kolon boylarının uzun veya kısa olması (Eğimli arazi, kısa kolon ve düşeyde düzensizlik sorunları).
- Temel sisteminin belirlenmesinde ve boyutlandırılmasında noksanlık olması sonucu zemin oturması meydana gelmesi.
- Düşey taşıyıcı elemanların (kolon, perde vb.) ve/veya kullanılan malzemelerin yetersizliği ve uygun şekilde donatılmaması.
- Genellikle zemin katların ticari amaçla kullanılması nedeniyle ortaya çıkan zayıf kat ve yumuşak kat sorunu.
- Planda düzensizlik meydana getiren büyük girinti ve çıkıntıların olması.
- Kapalı bir çerçeve sisteminin tanzim edilmemesi (kolonlara bağlanmayan kiriş), kolon akslarında yaşanan sapmalar ve çerçevelerdeki süreksizlikler.
- Proje aşamasında yapılan hatalar sonucu bant pencere oluşması ve dolayısı ile kat yüksekliği boyunca devam etmeyen duvarlarda kısa kolon oluşumuna sebebiyet verilmesi.
- Planda büyük boşlukların olması neticesinde rijit diyafram teşkil edilmesinin engellenmesi.
- Binada rijitlik merkezi ile ağırlık merkezinin birbirinden uzaklaşması ile oluşan burulma düzensizliği ve neticesinde kenar ve köşe kolonlarda problemlerin yaşanması.


- Kolonların konsollara oturması, binadaki ağır çıkmalar sebebiyle kolonların kirişlere bağlanamaması. (Ağır çıkma sorunu)
- Kolon-kiriş birleşim bölgelerinin yeterli hassasiyetle donatılmaması. (Beton kalitesinin yetersizliği, kenetlenme boylarındaki problemler, etriye aralıklarının fazla olması vb.)
- Bitişik nizam binalarda katların döşeme seviyelerinin farklı olması. (Çarpışma etkisi) (Bitişik nizam sorunu)
- Güçlü kolon-zayıf kiriş tasarımının terkedilmesi sonucu mafsallaşmanın kolonda oluşması.
- Düzgün bir şekilde tanzim edilmemiş çerçeve sistemlerde katlar arasında meydana gelen aşırı yer değiştirme (ötelenme).

Tecrübe edilen acı depremler sonucunda ortaya çıkan hasarlar yukarıda bahsedilen nedenlerden biri ya da birkaçının bir araya gelmesi neticesinde vuku bulmaktadır. Belirtilen sorunların yıllardır kesin bir çözüme kavuşturulmamasının da bu problemlerin tekrerrür etmesine sebebiyet verdiği aşikârdır. Bu noktadan hareketle yeniden inşa edilecek yapılar tasarlanırken oluşabilecek afetlere karşı yeterince mukavim davranabilen, uygun malzemelerin seçilmesi ile gerekli tasarım ve detaylandırmaların yapılması ve sürdürülebilir bir çevre oluşturulmasına önem verilmelidir.

3.1.1. Planda düzensizlik kaynaklı hasarlar

Depreme dayanıklı bina tasarımında basitlik ve simetri temel ilkeler olup bu tür ilkelere riayet edilerek yapılan yapıların deprem davranışları hem kolay anlaşılabilen hem de gerekli statik hesaplamalar detaylandırmalar daha kolay yapılabilir. Basit ve simetrik olmayan yapıların statik ve dinamik hesaplarının zor olmasının yanında çoğunlukla yapılan kabuller sebebiyle de yaklaşık çözümler üretilebilmekte ve bu tarz yapılarda burulma düzensizlikleri oluşabilmektedir. Bu nedenle yapıların basit geometrik şekillerle tasarlanarak projelendirilmesi önerilmektedir.

Plandaki düzensiz akslar, kolonlar ve konsollar yapının deprem davranışını olumsuz yönde etkilemektedir. Kirişlerle bağlantısı olmayan kolonlar, çerçeve sistemlerindeki süreksizlikler olası bir depremde ciddi hasarların oluşmasına sebebiyet vermektedir. Yapılan araştırmalar neticesinde betonarme yapılarda yaşanan depremlerin akabinde plan kaynaklı düzensizliklerden en çok burulma düzensizliği (A1), döşeme süreksizliği (A2), planda çıkıntı düzensizliği (A3) ve taşıyıcı eleman eksenlerinin paralel olmaması (A4) problemleri karşımıza çıkmaktadır. (Şekil 3.2) Söz konusu problemlerin bir veya birkaçının binada bulunması taşıyıcı sistem elemanlarının kapasitelerinde önemli düzeyde azalmalara, ciddi hasarların oluşmasına ve hatta binanın göçmesine neden olmaktadır.



Şekil 3.2. A3 (a, b ve c) ve A4 (d) türü plan düzensizlikleri

- **Burulma düzensizliği (A1)**

Herhangi bir katta meydana gelen en büyük görelî yer deđiřtirmenin ortalama görelî yer deđiřtirmeye bölünmesi ile elde edilen deđerin 1,2'den büyük olduđu řartlarda meydana gelen düzensizliđe burulma düzensizliđi denir. Burulma düzensizliđi katsayısı olarak tanımlanan η_b 'nin 2,0 üst sınır deđerini aşması halinde yapılarda aşırı burulma düzensizliđi gözlemlenir. Bu kořullarda eřdeđer deprem yükü yöntemi uygulaması uygun görülmez ve yapıya dinamik hesap yapılması önerilir (Özmen, 2004).

Burulma düzensizliđi genellikle ekonomik ömrünü tamamlamış ve sünek bir davranış sergileyecek řekilde tasarlanmamış olan yapılarda kesme kuvvetinin etkisiyle büyük hasarların oluşmasına sebebiyet vermektedir. Yapılarda oluşan ciddi miktardaki deplasmanlar, gevrek davranış sergileyen kolon ve perdeler göçme riskini önemli oranda artırmaktadır. Yumuřak kat ve zayıf kat mevcudiyeti ve gerekli hassasiyet gösterilmeden teřkil edilmiş donatıların bulunduđu yapılarda söz konusu hasarla, çođu deprem neticesinde sıklıkla karşılaşılmıştır.

Burulma düzensizliđine sebebiyet veren parametreleri sıralayacak olursak:

- Binanın plan geometrisinin uygun olmayışı (Mimari kaygılar nedeniyle L, T ve U řeklinde binaların tasarlanması) (uygun olmayan řekillerden kaynaklı gerilme yığılmalarının oluşması), rijitlik davranışının yeterli olmaması.
- Simetrik olmayan bir řekilde perdelerin planda dağılması.
- Yapının kütle merkezi ile ađırlık merkezi arasında mesafe farkı olması.
- Hareketli yük ve dolgu duvar dağılımının planda düzensiz bir řekilde dağılması.
- Binada bulunan aksların düzenli ve simetrik olarak konumlanmaması.
- Bina kat adedi.

Şekil 3.3. ve 3.4'te burulma düzensizliği kaynaklı problemler nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.3. 1999 Kocaeli depremi sonrasında burulma hasarı görülen kamu binası (Çağatay ve ark, 2007)



Şekil 3.4. 1994 Northridge depreminde meydana gelen burulma hasarı (FEMA-454, 2006)

- **Döşeme süreksizliği (A2)**

Binalarda merdiven kovası, aydınlatma ve asansör boşluğu oluşturmak için bırakılan döşeme yırtıkları ani mukavemet kaybına sebebiyet vermektedir. Oluşturulan bu boşluklar yatay deprem yüklerinin çerçeveler arasında güvenle aktarılmasını engeller ve döşeme süreksizliği düzensizliğinin oluşmasına neden olur. Döşeme plağının rijit diyafram olarak düzlemi içerisinde şekil değiştirmeden davranması istenir.

Bilhassa depremlerin yoğun olarak yaşandığı bölgelerde inşa edilen yapılarda, mimari gerekçelerle meydana gelen hatalar depremde oluşacak enerjileri sönümleme noktasında yetersiz kalacağından söz konusu yapılarda büyük hasarlara sebebiyet vermektedir. Yapıların büyük çoğunluğunda çeşitli sebeplerle oluşturulmuş döşeme yırtıkları bulunmaktadır. Olası bir depremde bu boşluk bölgelerinin kesme kuvvetlerini süreklilik arz eden bir biçimde kolonlara iletmesi mecburidir. Diğer taraftan, döşemelerin rijit diyafram olarak işlevini yapması ve yapının genel performansına olumsuz yönde etki etmemesi sağlanmalıdır. Döşemelerde bırakılan söz konusu boşluklar sebebiyle kirişlerde süreksizlikler oluşmakta ve yapılarda ciddi anlamda deplasmanlar meydana gelmektedir. Böylesi bir durumun hiçbir yapıda oluşması istenmemektedir. Bununla beraber döşemedeki yırtıkların simetrik bir şekilde tasarlanmaması halinde yapılarda burulma düzensizliğinin oluşmasına da sebebiyet verilmektedir (Öztürk, 2013). Şekil 3.5'te döşeme süreksizliği kaynaklı problemler nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.5. (a) 2017 Meksika depreminde görülen döşeme hasarı (Burke, 2017) (b) 2009 İtalya L'aquila depreminde meydana gelen döşeme hasarı (Lauro, 2009)

- **Planda çıkıntı düzensizliği (A3)**

Türkiye'deki mevcut yapı stoğu içerisinde, kapalı ve açık çıkmalı kısımlar imar yönetmeliklerinin izin verdiği çerçevede oldukça sık uygulanmaktadır. Söz konusu kapalı ve açık çıkmalar yapıların kütle dağılımını büyük oranda etkilemektedir ki bu da bahse konu yapıların deprem performansını olumsuz anlamda etkilemektedir. Yapının tamamında uygulanan bu çıkmalar hem kirişlerin hem de döşemelerin binanın oturum alanından dışarıya doğru sarkmasına sebebiyet vererek çerçeve sisteminde kirişsiz bir bölüm oluşturmaktadır. Netice itibarı ile oluşan süreksiz kirişler oldukça zayıf çerçeve sistemlerinin meydana gelmesini sağlamaktadır (Bal ve ark., 2006).

Şekil 3.6'da planda çıkıntı düzensizliği kaynaklı problem nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.6. Planda çıkıntı düzensizliği sonucu çöken bir bina (Atabey, 2022)

3.1.2. Düşey doğrultuda düzensizlik kaynaklı hasarlar

Düşey doğrultuda düzensizlikler; katlar arası dayanım düzensizliği (zayıf kat) (B1), komşu katlar arasındaki rijitlik düzensizliği (yumuşak kat) (B2), düşey elemanların süreksizliği (B3), olarak 3 farklı şekilde karşımıza çıkmaktadır. Depreme dayanıklı bina tasarımında plan geometrisinde olduğu gibi binanın yüksekliği boyunca da oluşan geometrisinde basitlik, simetriklik ve süreklilik istenen önemli özelliklerdir. Düşey taşıyıcı elemanların bina yüksekliği boyunca süreksiz bir şekilde inşa edilmeleri neticesinde, olası depremlerde ciddi hasarlar hatta toptan göçmeler yaşanmaktadır.

- **Katlar arası dayanım düzensizliği (B1)**

Yapısında düşey yönde dayanım düzensizliği bulunan katlara zayıf kat adı verilir. Endonezya, Şili, Alaska, Filipinler ve Türkiye'de vuku bulan depremler neticesinde zayıf kat hasarı görmüş çok sayıda yapıya rastlamak mümkündür. Bilhassa yapıların zemin katları ticari amaç doğrultusunda tasarlandığı için söz konusu alanlarda taşıyıcı özellik sergileyen duvarlar bulunmamaktadır. Bu sebepten ötürü zemin katlarda deplasmanlar daha büyük mertebelere erişmekte ve dolayısı ile kesme kuvveti tesiriyle zayıf kat düzensizliği oluşmaktadır (Tezcan ve ark., 2004).

Yapıların farklı bölümlerinde farklı oranlarda bölme duvarların teşkil edilmesi durumunda söz konusu yapıların orta katlarında ve kat yükseklikleri farklılık arz eden yapılarda da katlar arası dayanım düzensizliğine oldukça sık rastlamak mümkündür. Deprem neticesinde katlar arasında aşırı ötelenme farklarının oluşmaması istenir. Ancak söz konusu düzensizliğin var olduğu yapılarda bu farklar oldukça büyük mertebelere erişmektedir. Oluşan az miktardaki plastik mafsallar kolonların uç kısımlarında meydana gelmekte ve kesme kuvvetlerini absorbe edemeyerek göçme mekanizmasının oluşmasına sebebiyet vermektedir.

Zayıf kat probleminin en dikkat çekici oluşum sebebi yığma duvarların statik hesaplarda dikkate alınmamasıdır. Taşıyıcı sistem hesaplamalarında yığma duvarların göz önünde bulundurulması durumunda yapıların iç kısımlarındaki kesit boyutları daha minimize olur. Kesit zorlarının düşük olması statik açıdan yapıların zayıflık arz etmesine sebebiyet verebilir. Taşıyıcı duvarların yer aldığı katlarda ötelenmeler büyük oranda azalır. Dolayısı ile yapıların ilk doğal periyodunun hesaplanmasında taşıyıcı duvarların etkileri dikkate alınmalıdır. Bu etkilerin dikkate alınmaması ve üst katlarda bulunan taşıyıcı duvarların zemin katta bulunmaması halinde zayıf kat hasarının oluşması kuvvetle muhtemeldir (Tezcan ve ark, 2007).

Şekil 3.7’de 2003 yılında Bingöl ilinde yaşanan depremde zayıf kat hasarı kaynaklı problem nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.7. 1999 Kocaeli depremi zayıf kat hasarı (Sezen ve ark, 2000)

- **Katlar arası rijitlik düzensizliği (B2)**

Katlar arası rijitlik düzensizliği, bir yapıdaki herhangi bir katın diğer katlara nispetle daha az rijit olması halinde ortaya çıkar. Bu düzensizlik türü çeşitli yayınlarda yumuşak kat veya esnek kat olarak da isimlendirilmektedir. Yumuşak kat düzensizliği taşıyıcı özelliği olmayan duvarların eksilmesi neticesinde karşılaşılan bir problemdir. Yapılara ilişkin modellemeleri gerçekleştiren teknik uzmanlar, bu düzensizliği dikkate almazlarsa deprem neticesinde oluşacak olan kesme kuvvetleri sebebiyle söz konusu yapıların bütünüyle göçmesi ile karşılaşılabilir (Charleson, 2014).

Tasarımı simetrik olarak yapılmış yapılarda kesme kuvveti, yapının her katında düzenli bir şekilde artış göstermekteyken asimetrik olarak inşa edilmiş yapılarda ise böyle bir dağılımın oluşmasını beklemek mümkün değildir. Katlar arası rijitlik düzensizliği bulunan yapılarda bilhassa zemin kat daha büyük oranda enerji absorbe eder ve kolonlarda daha fazla hasar meydana gelir.

Büyük oranda zemin kat ile bir üst kat arasında meydana gelen bu problem büyük hasarlara ve bütünüyle göçmelere sebebiyet vermektedir (Guevara, 2012).

Şekil 3.8’de 2011 yılında Van ilinde yaşanan depremde yumuşak kat hasarı kaynaklı problem nedeniyle oluşan hasarlar gösterilmiştir




Şekil 3.8. 2011 Van depreminde yumuşak kat düzensizliğine bağlı oluşan hasarlar (İKÜ-CE,2011)

- **Düşey elemanların süreksizliği (B3)**

Yapılarda estetik kaygılar ve mimari gereksinimler sebebiyle çok miktarda yapısal düzensizlik meydana gelmekte ve bu düzensizlikler de yapıların depreme ilişkin performanslarını menfi yönde etkilemektedir. Dünyanın birçok farklı ülkesinde deprem adına oluşturulmuş yönetmeliklerde söz konusu düzensizliğin ortadan kaldırılması için çeşitli düzenlemeler yapılmıştır. Bu yönetmeliklere rağmen birçok düzensizlik, uygulama hataları sebebiyle gözlemlenmektedir. Yatayda oluşan düzensizlikler yapının hâkim periyonu değiştirerek deprem performansını da kötüleştirmektedir. Düşey elemanlarda meydana gelen düzensizlikler de katlar arası rijitlik düzensizliği ve katlar arası dayanım düzensizliği problemlerini doğurmaktadır. TBDY-2018’de taşıyıcı sistem elemanlarının süreksizliğine ilişkin ciddi düzenlemelere yer verilmiştir. Bu bağlamda düşey taşıyıcı sistem elemanlarının (perde ve kolon) süreksiz tasarlanmasına engel olunmuştur. Ayrıca, kolon üzerine teşkil edilmiş perdelere, konsol çalışan kirişlere oturtulan kolonların tasarlanmasına izin verilmemiştir (Celep ve ark., 2012).

Geometrik anlamda ciddi düzensizliği bulunan yapılarda sünek davranış istemi düzenli yapılara nispetle daha fazladır. Asimetrik biçimde inşa edilmiş yapılarda kesitlerin ciddi değişikliğe uğradığı bölgelerde plastik davranış hâkimiyeti yaşanmaktadır. Bu nedenden ötürü ani kesit değişikliğinin olduğu bu bölgelerde olası bir depremde meydana gelen kesit tesirleri ile oldukça fazla zorlanmalar yaşanacaktır (Alirezai ve ark., 2015).

Şekil 3.9’da 2010 yılında Şili’de yaşanan depremde düşey elemanların süreksizliği kaynaklı problem nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.9. 2010 Şili depreminde düşey geometrisi düzensiz bina hasarları (Elnashai ve ark.,2010)

3.1.3. Kısa kolon kaynaklı hasarlar

Kolon etkili boyunun azaltılması neticesinde yatay deprem kuvvetine maruz kalan düşey taşıyıcı sistem elemanın boşluk yüksekliği kadar olan bölgede eğilmeye zorlanması sonucunda ortaya çıkan taşıyıcı sistem hasarı, kısa kolon hasarı olarak isimlendirilir (Yön ve Sayın, 2008).

Mimari kaygılar sebebiyle statik gereklilikler yeterince dikkate alınmadan tasarlanan bilhassa okul, hastane ve diğer kamu yapıları gibi birçok yapıda teşkil edilen bant pencereler, deprem neticesinde sıklıkla ortaya çıkan kısa kolon probleminin ana kaynağıdır. Yapıların bodrumlarında havalandırma ve ışıklandırma gereksinimlerinin giderilmesi için oluşturulan pencereler deprem neticesinde yapının hasara uğramasına büyük oranda katkı sağlamaktadır. Tüm teknik uzmanların (mühendis, mimar vb.) yapıları modellerken veya inşa ederken söz konusu hasarların oluşmasının mümkün olduğu bölgeleri tespit etmesi ve elzem olan tedbirleri alması söz konusu yapıların depreme karşı dayanıklılığı açısından hayati önem arz etmektedir (Guevara ve ark., 2005).

Şekil 3.10'da 2011 yılında Yeni Zelanda'da yaşanan depremde kısa kolon kaynaklı problem nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.10. 2011 Christchurch depremi kısa kolon hasarı (Lim, 2011)

3.1.4. Bitişik nizam inşa edilmiş binalar kaynaklı hasarlar (Çarpışma etkisi)

Birbirine bitişik olarak inşa edilen fakat aralarında derz mesafesi bulunmayan yapılarda deprem titreşimleri sırasında, çarpışma neticesinde öngörülemeyen hasarlar meydana gelebilmektedir. Eğer söz konusu iki bitişik yapının kat düzeyleri ve dinamik özellikleri de farklı ise komşu kolonlarda ağır hasarlar oluşmakta ve bu duruma çarpışma etkisi (çekiçleme) denilmektedir.

Çarpışma etkisi neticesinde oluşan hasar tiplerini sınıflandıracak olursak:

- Farklı kütleli binalarda çekiçleme etkisi.
- Kolon döşeme etkileşimi nedeniyle meydana gelen çarpışma etkisi.
- Farklı yükseklikli binalarda görülen çekiçleme etkisi.
- Sıralı binalarda meydana gelen çekiçleme etkisi.
- Çekiçleme nedeni ile burulan binalar.

Şekil 3.11’de 2011 yılında Van ilinde yaşanan depremde çarpışma etkisi ve yumuşak kat kaynaklı, Şekil 3.12’de de farklı kütleli iki binanın çekiçleme etkiyle oluşturduğu problem nedeniyle oluşan hasarlar gösterilmiştir.



Şekil 3.11. Çekiçleme etkisi sebebiyle göçen bir bina (Öztürk, 2015)



Şekil 3.12. Farklı kütleli çekiçleme etkiyle ciddi hasar almış bir işyeri ve konut (Cole ve ark., 2012)

3.1.5. Donatı kaynaklı hasarlar

Depremlerde ağır hasar alan binaların büyük çoğunluğunda tipik donatı kusurları olduğu gözlenmiştir. Kolon-kiriş birleşim bölgelerinin yeterince iyi tasarlanıp donatılmaması, söz konusu bölgelerde etriye sıklaştırmasının yapılmaması, donatı kenetlenme boyunun yetersiz olması, deprem çirozlarının olmaması veya yeterince olmaması, nervürlü donatı kullanılmaması nedeniyle aderansın yetersiz olması ve sonucunda donatının betondan sıyrılması, etriyelerde kanca bulunmaması veya kanca detaylarının yönetmeliklere uygun olmaması, donatı burkulma boyunun etkisi, donatı çaplarının uygun seçilmemesi, donatı yerleşimlerinin uygun yapılmaması en çok rastlanılan donatı kaynaklı hasarlar olarak sıralanabilir

Şekil 3.13, Şekil 3.14, Şekil 3.15, Şekil 3.16, Şekil 3.17’de donatı kaynaklı hasarlara ilişkin görseller verilmiştir.



Şekil 3.13. Kolon-kiriş birleşim bölgelerinde oluşan hasarlar (Gürer, 2012)



Şekil 3.14. 2010 Şili depreminde yaşanan burkulma hasarları (Harris ve ark., 2011)



Şekil 3.15. Sargısız kolon-kiriş birleşim noktası hasarları (Topçu, 2019)



Şekil 3.16. 2011 Van depreminde donatı detaylandırma hatalarına bağlı hasarlara örnekler (İKÜ-CE, 2011)



Şekil 3.17. 2011 Van depreminde kolon sarılma bölgelerinde meydana gelen hasarlara örnekler (İKÜ-CE, 2011)

3.1.6. Beton kalitesi kaynaklı hasarlar

İnşaat yapımında uygun olmayan agrega kullanılması, su/çimento kaynaklı sorunlar, betonun iyi sıkıştırılmaması, betonun üretiminde, yerine yerleştirilmesinde ve kür şartlarında yaşanan problemler olası bir depremde ciddi hasarlara yol açabilmektedir.

Belirtilen problemler sonucu betonun basınç dayanımında yaşanacak azalmalar betonarme yapının davranışını olumsuz anlamda büyük oranda etkilemektedir. Beton, yapısı gereği sünek bir

malzeme olmadığından hem enerjiyi absorbe edebilme kapasitesi hem de çekme mukavemeti çok düşüktür. Söz konusu sünek davranışı sergilemesi için betonun içerisine donatı yerleştirilmektedir. Betonunun basınç mukavemetinin oldukça düşük seviyelerde olması halinde donatı ve beton arasındaki aderans, düşük gerilmelerde dahi istenilen kenetlenmeyi karşılayamaz. Böylesi bir durumda donatı betondan kolaylıkla ayrılır ve enine donatılarla çevrelenmiş olan boyuna donatılar burulma etkisi altında kalır ve dolayısı ile beton parçalanır, donatı kopma mukavemeti aşar bunların sonucu olarak da bu etkilere maruz kalan bir yapıda göçme durumuna evrilir. Düşük basınç mukavemeti düşey taşıyıcı elemanların eksenel yük ve moment yutma kapasitelerini azaltır. Kiriş ve kolonların uç kısımlarında meydana gelen plastik mafsallar deprem durumunda yüksek mertebelerde enerji absorbe etme kabiliyetine sahiptir. Mafsalların sünek bir davranış sergilemesi için kolonlardaki boyuna donatı ile kirişlerdeki donatıların kuvvetli bir kenetlenme ile meydana gelen gerilmeleri betona iletmesi beklenir. Düşük mukavemetli betonlarda kesme kuvveti sebebiyle betonda çatlaklar ve ayrılmalar ortaya çıkmaktadır. Aynı zamanda benzer özelliklere sahip betonların; moment, eksenel yük ve kesme kuvveti taşıma kapasiteleri de düşüktür.

Şekil 3.18. ve Şekil 3.19'da beton kalitesinden ve malzemeden kaynaklanan hasarlara ilişkin görseller yer almaktadır.



Şekil 3.18. Segregasyona uğramış ve uygun agrega seçimi yapılmamış beton numuneleri (Yepez, 2017)



Şekil 3.19. 1985 Meksika depreminde meydana gelen yapı malzemesi kaynaklı hasarlar (Adler, 2015)

3.1.7. Rijitlik yetersizliği kaynaklı hasarlar

Depremlerde yapılan gözlemler özellikle düşey taşıyıcı elemanların rijitliklerinin deprem dayanımı için oldukça önem arz ettiğini göstermiştir. Çok şiddetli depremlerde dahi ayakta kalabilen binalarda yapılan incelemelerde çok fazla miktarda perde tasarlandığı dikkat çekmiştir. Ülkemizde yaşanan depremler sonucunda binalarda yanal rijitliğin yetersiz olduğu ve sünek çerçeve sistemlerin teşkil edilmediği gerçeği ortaya çıkmıştır.

Diğer taraftan, güçlü sismisite durumlarında ikinci mertbe tesirlerinin azaltılması ve taşıyıcı özelliği bulunmayan duvarlardaki hasarların üst düzeylerde olmaması için çerçeve sistemlerin yanal rijitliklerinin söz konusu tesirleri sönmüleyebilecek seviyede olması elzemdir. Yeterli düzeyde yanal rijitliğe sahip olmayan binalarda deprem esnasında aşırı yatay ötelenmeler, kolon uçlarında mafsallaşmalar oluşmakta ve dolayısı ile de söz konusu binaların göçtüğü görülmektedir.

Yapı için yeterli rijitlik; ikinci mertbe momentlerini mümkün olduğunca küçültmek, sıkça oluşan depremlerde yani kullanılabilirlik sınır durumuna karşı gelen depremlerde yapısal olmayan hasarları azaltmak için gerekli olmaktadır. Yatay yükler etkisinde yapı rijitliğinin en önemli ölçütü elemanın kendi rijitliği ve yapıda bir katın alt kata göre yapmış olduğu görelî öteleme miktarıdır. Rijitlik için yapının geometrisi değil, düşey taşıyıcıların konumu ve bunların her iki doğrultudaki boyutları önemli olmaktadır. Betonarme bir yapıda düşey taşıyıcı elemanlar olarak kolon ve perdeler dolgu duvarlara göre daha rijit davrandığı için, rijitlik hesabında bu elemanların dikkate alınması yeterli olmaktadır. Düşey taşıyıcı elemanların rijitliklerinin hesabında elemanlarda kullanılan malzemenin özellikleri (elastisite modülü), elemanın enkesit boyutları ve elemanın uçlarının mesnetlenme biçimleri etkili olmaktadır.

Betonarme yapılarda teşkil edilen kesitlerin geometrik özelliklerinden ve/veya söz konusu yapılara asimetric olarak gelen yüklemelerden kaynaklı burulma momentleri oluşmaktadır. Düşey taşıyıcı elemanlardan perdelerin boyutlarına ve plan üzerinde konumlandırılmasına göre yapıların burulma rijitlikleri farklılık göstermektedir. Bahse konu düşey taşıyıcı elemanlar hem istenilen seviyede burkulma kapasitesine sahip olmalı hem de devrilme momentlerini karşılayacak özellikte dizayn edilmelidir. Ayrıca perdeler planda simetric olarak yerleştirilmeli ve dolayısı ile rijitlik dağılımının homojen hale getirilmesi sağlanmalıdır. Bu hususlara dikkate edilmediği takdirde yapı içerisinde bazı perdeler ciddi zorlanmalara maruz kalır iken bazıları da oldukça düşük seviyelerde zorlanacaklardır. Perdelerin maruz kaldığı burkulma tesirlerini minimize etmek amacıyla plan içerisinde en uygun şekliyle yerleştirilmeleri gerekmektedir. Buna göre;

- Yapıda en büyük burulma rijitliğinin sağlanması için, perde duvarlar yapının çevresine dağıtılmalıdır.

- Perde duvarlar kat planı içinde, döşeme yüklerinin olabildiğince büyük kısmını, aksel kuvvet olarak temele aktaracak şekilde düzenlenmelidir. Bu şekilde perdede eğilme momenti için gereken donatı azalacaktır.
- Çok katlı yapılarda deprem direncinin birkaç perdede yoğunlaştırılması, temel sistemini bu noktalarda çok büyük deprem etkisine maruz bırakacaktır. Bu durumdan, ekonomik olmayan ağır bir temel sistemini gerektirdiğinden, kaçınılmalıdır.
- Perde duvarlar, her iki doğrultuda yerleştirilmelidir.

Şekil 3.20. ve Şekil 3.21’de rijitlik yetersizliğinden kaynaklanan hasarlara ilişkin görseller yer almaktadır.



Şekil 3.20. 2011 Van depreminde plastik mafsallaşma yaşanan binalar (İKÜ-CE, 2011)



Şekil 3.21. Van depreminde yeterli yanal rijitliğe sahip olmayan binalarda gözlenen hasarlar (İKÜ-CE, 2011)

3.1.8. Zemin kaynaklı hasarlar

Depremler sonrasında yapılan incelemeler, binalarda hasarların oluşmasında zemin özelliklerinin belirleyici olduğu gerçeğini ortaya çıkarmıştır. Bölgenin depremselliğinin önceden biliniyor olmasına karşın bilinçsiz planlama ve zemin özelliklerine uymayan düzensiz yapılaşma depremler sonucunda oluşacak hasarların başlıca nedenleri arasında yer almaktadır.

Diğer taraftan, yapıların inşa edildikleri zeminin durumuna göre deprem esnasındaki davranışları değişiklik gösterebilmektedir. Diğer bir ifade ile deprem yükleri altındaki davranışları temel zemininden bağımsız değildir. Bu nedenle binaların inşa edileceği zeminin mühendislik parametrelerinin bilinmesi zorunluluğu ortaya çıkmaktadır.

Zemin koşulları sebebiyle binalarda oluşabilecek hasarları şu şekilde özetlemek mümkündür:

- Eğimli arazi üzerine binaların inşa edilmesi sonucu maruz kalacağı deprem etkisinin artması.
- Jeolojik ve topoğrafik nedenlerden dolayı bazı durumlarda binanın zeminle birleştiği katta seviye farkları oluşması neticesinde binanın en alt katında yer alan kolon elemanları arasındaki yükseklik farklarına neden olarak kolon boylarının uzun veya kısa olması. (Eğimli arazi sorunu)
- Zemin tabakalarında sıvılaşmanın gözlemlenmesi (Şekil 3.22).
- Zemin tabakalarında oturma ve göçmelerin oluşması (Şekil 3.23).
- Yamaçlarda stabilitenin bozulması nedeniyle binaların toptan göçmesi.



Şekil 3.22. Zemin sıvılaşması problemi sonucu devrilen bir bina (Sezen ve ark, 2000)



Şekil 3.23. 2020 İzmir depreminde zeminde farklı oturma ve yumuşak kat sorunu yaşayan bir bina (Anonim, 2022)

3.1.9. Korozyon kaynaklı hasarlar

Deprem bölgelerinde birçok betonarme yapıda yapılan detaylı incelemeler neticesinde, doğrudan deprem sebebiyle meydana gelmemiş çatlakların bulunduğu birçok taşıyıcı sistem elemanı ile karşılaşılmıştır. Kesit özellikleri ve taşıyıcı sisteme tesiri dikkate değer seviyede olan yapısal çatlakların temel anlamda meydana gelme sebebi; perde, kolon, kiriş ve döşeme elemanlarındaki donatıların korozyona uğramış olmasıdır (Şekil 3.24).

Yapı elemanlarındaki betonun kalitesinin düşük olması durumunda beton ciddi anlamda çevresel etkilere maruz kalarak bünyesindeki donatıyı muhafaza edemez. Donatıların muhafaza edilmesi için bırakılan pas payının az olması donatının söz konusu çevresel etkilere maruz kalarak korozyona uğramasını sağlayan başlıca etmendir. Hava içerisinde bulunan karbondioksitin betonun yapısındaki boşluklara nüfuz ederek hidrasyona uğraması neticesinde ortaya çıkan kalsiyum hidroksitle tepkimeye girmesi sonucunda kalsiyum, karbonata evrilir ve ortamdaki Ph (hidrojen gücü ya da power of hydrogen) derecesi 11-12'den 8 seviyelerine iner. Netice itibarı ile donatı üzerinde var olan pasivasyon yüzeyinin hasara uğraması ile korozyon oluşur.

Donatının korozyona maruz kalmasının diğer bir sebebi de klor iyonlarıdır. Korozyonun başlaması ve sürekli bir şekilde ilerlemesi için betonun yeterince geçirimsiz olmayıp CO₂, Cl₂ O₂ ve nem difüzyonuna mâni olmaması gerekir. Donatının korozyona uğramasını engellemenin en başta gelen tedbirlerinden ilki su/çimento yüzdesini azaltmak ikincisi ise çimentonun dozajıdır. Bilhassa klor maruziyetinin fazla olduğu sahil şeridindeki yapılarda durabiliteyi sağlamak için gerekli beton mukavemetinden daha yüksek dayanımlı beton kullanmak elzemdir. Şekil 3.23'te korozyona uğramış, pas payı bütünüyle yok olmuş taşıyıcı elemanlar görülmektedir. Korozyon sebebiyle donatı çapları küçülmüş ve hatta etriyelerde kopmalar gerçekleşmiştir. Korozyonu bertaraf etmenin başlıca metodu betonu olabildiğince geçirimsiz hale getirmekten geçer. Su/çimento yüzdesi düşük, yönetmeliklerde belirtilen standartlar uyarınca titreşim uygulanarak yerleştirilmiş, ihtiyaca uygun pas payı bırakılmış ve betonun bakımı yapılmış yapılarda korozyonu ortadan kaldırmak mümkündür (Taşdemir ve ark., 2000).



Şekil 3.24. Korozyona maruz kalmış donatı örnekleri (Taşdemir ve ark., 2000)

3.1.10. Zayıf kolon-kuvvetli kiriş tasarımı kaynaklı hasarlar

Deprem anında yapısal elemanların en önemli davranışı kolon kiriş birleşim noktalarındaki dönme kapasiteleridir. Kuvvetli kolon zayıf kiriş prensibi kolon dönme kapasitesinin kiriş dönme kapasitesinden daha büyük olması olarak tanımlanır. Sismik etkiler altında karmaşık çerçeve sistemli bir yapının doğrusal davranış gösterebilmesi için sünekliğinin yüksek ve enerji yutma kapasitesinin yeterli düzeyde olması gerekir. İstenen koşulların sağlanabilmesi için yapının kuvvetli kolon zayıf kiriş davranışına göre tasarlanması şarttır (Liu ve Zheng, 2012).

Kolon kiriş birleşim noktasındaki alt ve üst kolonların moment taşıma kapasiteleri toplamının kirişlerin moment taşıma güçleri toplamından %20 daha fazla olması istenir. Burada iki hedef söz konusudur. Birinci amaç kolonlarda elastik mafsall oluşmaması, ikincisi ise kirişlerde meydana gelen plastik mafsalların yapı sisteminin sünekliğinin yükselmesine katkı sağlamaktır.

Kuvvetli kolon zayıf kiriş tasarımında herhangi bir düğüm noktasına birleşen kolonların toplam eğilme momentleri aynı düğüm noktasına birleşen kirişlerin toplam eğilme momentlerinden büyük olması istenir. Plastik mafsalların öncelikle sünek kirişlerde oluşması istenir. Taşıyıcı sistem tasarlanırken sistemin tümü için kesme ve aderans problemleri meydana gelmeyecek boyutlandırma esastır (Özer, 2007).

Kolon-kiriş birleşim bölgeleri deprem anında binada en çok zorlanan ve en çok önem arz eden noktalardır. Bu yüzden bu bölgelerin boyutlandırılmasında ve donatılmasında daha hassas davranmak gerekmektedir. Bu hassasiyeti sağlamak adına kolon-kiriş birleşim bölgelerinde aşağıda belirtilen hususlara riayet etmek uygun olacaktır.

- Birleşim noktası, seçilen plastik mafsallın maksimum talebini karşılayacak şekilde boyutlandırılmalıdır.
- Birleşim noktasında kirişin tek taraflı mesnetlenmesi nedeniyle kolonun kapasitesi etkilenmemeli ve ayrılma tehlikesi oluşturmamalıdır.
- Birleşim bölgelerinde oluşan deformasyon, kat kaymalarını attırmamalı ve çerçeve rijitliğini azaltmamalıdır.
- Kolon-kiriş birleşiminde donatı yoğunluğu nedeniyle sıkışıklık oluşmamalı ve aderans problemleri meydana gelmemelidir.

Yukarıda belirtilen tasarım esasları dikkate alınmadan, tam aksine zayıf bir kolona güçlü bir kirişin bağlanması ile çerçeve sistemlerin teşkil edildiği binalarda kolon-kiriş birleşimlerinde, yetersiz donatı ve yetersiz kesit nedeniyle deprem kuvvetleriyle oluşan enerji tüketilemediğinden, olası depremler neticesinde ciddi hasarlar ve toptan göçmeler meydana gelmektedir (Şekil 3.25).

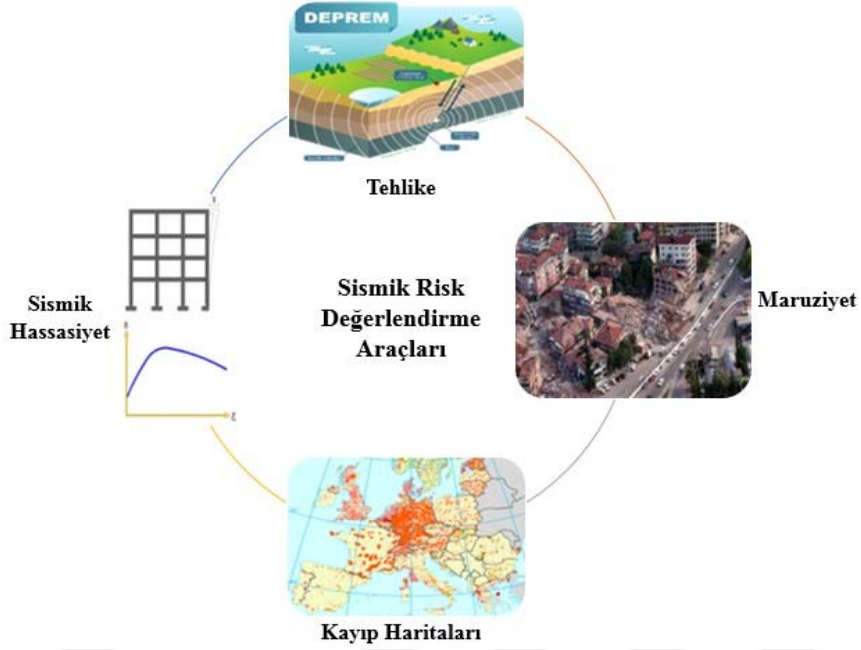


Şekil 3.25. 1999 Kocaeli depreminde zayıf kolon güçlü kiriş tasarımı sonucu yıkılan bina örnekleri (Sezen ve ark, 2000)

3.2. Deprem Öncesi Hızlı Sismik Değerlendirme Yöntemleri

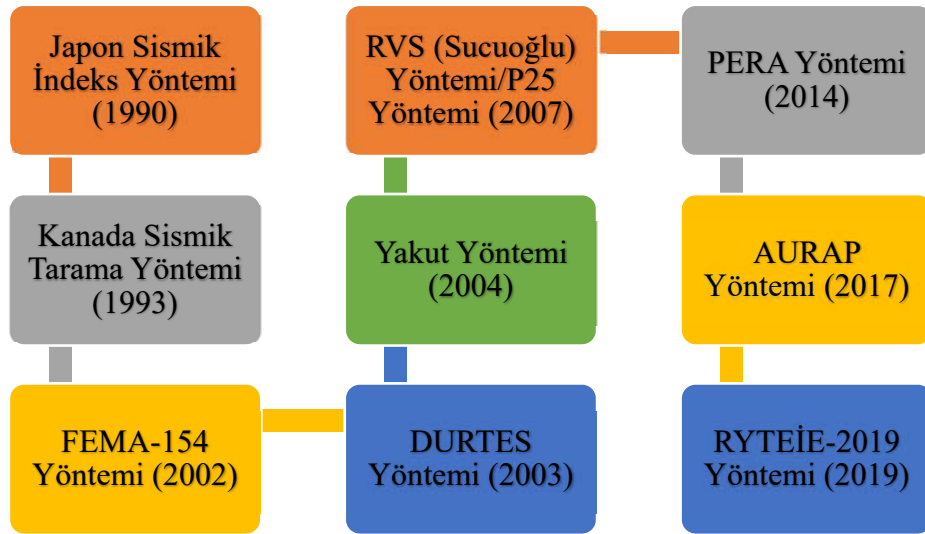
Türkiye gibi yüz ölçümünün büyük çoğunluğu ciddi deprem tehlikesi altında olan bir ülkede bu doğa olayının sonucunda oluşabilecek kayıpların en aza indirilmesi ülkemizin önemli bir meselesidir. Nüfusunun önemli bir kısmını deprem tehlikesi içinde barındıran ülkemizin yapılarının güvenlik seviyesinin belirlenmesi söz konusu afetlere karşı yapılacak hazırlıkların en önemli ve başta gelen safhalarından biridir.

Ancak incelenmesi gereken yapı stokunun büyüklüğü, bu değerlendirmenin yapılabilmesinin önündeki en büyük engeldir. Bu denli çok sayıdaki binanın detaylı şekilde incelenmesi mümkün değildir. Bu nedenle yapıların güvenlik seviyeleri hakkında fikir verebilecek, çok ayrıntılı bilgilere ihtiyaç duymayan hızlı ve pratik biçimde uygulanabilecek metotlara gereksinim duyulmuştur. Şekil 3.26'da sismik risk değerlendirme araçlarına ilişkin genel şematik gösterim verilmiştir.



Şekil 3.26. Sismik risk değerlendirme araçlarının genel şematik gösterimi

Belirli kabullere dayanarak, fazlaca detaya inilmeden yapıların güvenlik seviyesinin belirlenmesini sağlayan bu yöntemlere “Hızlı Değerlendirme Yöntemleri” denilmektedir. Bu noktadan hareketle tez çalışmasının temel amacı, bahsi geçen Hızlı Değerlendirme Yöntemlerinde dikkate alınan parametrelerden; ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi durumlarını Ön Eğitilmiş KSA yapılarını kullanmak suretiyle daha hızlı ve doğru bir şekilde tespit edebilen inovatif bir yöntem geliştirmektir. Tez çalışması kapsamında ele alınan Hızlı Değerlendirme Yöntemlerinin kronolojik sıralaması Şekil 3.27’de verilmiştir.



Şekil 3.27. Hızlı sismik değerlendirme yöntemleri kronolojisi

3.2.1. FEMA-154 yöntemi

Federal Acil Durum Yönetim Ajansı (2002) tarafından geliştirilen FEMA-154 (ATC 21) Deprem Riski Altındaki Binaların Hızlı Davranış Değerlendirme Yöntemi, binaların dışarıdan gözlemlenmesine dayanan, depremde önemli hasar görecekteki yapıların hızlı bir şekilde tespitine olanak sağlayan bir Amerikan yöntemidir. Yöntemin uygulanması kolay ve nispeten az masraflı olup taşıyıcı sistemle ilgili herhangi bir statik hesap gerektirmemektedir. Bu yöntem ülke genelinde yapılacak bir deprem güvenliği çalışmasında deprem etkisine karşı açık bir şekilde eksikliği bulunan mevcut binaların hızlı bir şekilde tespit edilmesini mümkün kılacağından bir ön değerlendirme aşaması olarak kullanılabilir. Değerlendirme sadece elde edilen bilgilerin puanlandırılması şeklindedir. İncelenecek olan binanın bulunduğu deprem bölgesine göre veri toplama formları seçilir ve bina tipine göre de ana puanı elde edilir. Daha sonra binanın deprem davranışını kötü yönde etkileyebilecek olan faktörler yerinde saptanır. Değerlendirme aşaması; taşıyıcı sistemin belirlenmesi ve kullanılan malzemenin tanımlanması şeklinde olmakla birlikte, tüm toplanan bilgilerin puanlandırılması esasına dayanır. Daha sonra bu puana, binanın deprem performansını değiştirebilecek olan faktörlerin formda verilmiş değerleri çıkartılarak, karar için gerekli olan binaya ait nihai puan (S) elde edilir. Nihai puanın yüksek çıkması, binanın deprem dayanımının da yüksek çıkacağı anlamına gelir. Elde edilen puanın 2'den küçük çıkması ayrıntılı incelemeyi gerektirir. Ancak yapıyı inceleyen uzmanın görüşleri daha fazla önem arz etmektedir. Bu noktadan hareketle; ATC 21, mevcut yapıları 2 ayrı gruba ayırmaktadır. Bu gruplardan birincisi, deprem performansı yeterli olan ($S > 2$), ikincisi ise deprem dayanımı yetersiz olan ve ayrıntılı incelemeye gerek duyulan binalardır ($S < 2$).

3.2.2. Yakut yöntemi

Yakut (2004) tarafından betonarme binaların hızlı sismik değerlendirilmesi için geliştirilmiş bir yöntemdir. Türkiye'deki bina koşulları dikkate alınarak betonarme yapı sistemleri için geliştirilen bu yöntemin uygulanabilmesi için bina taşıyıcı sisteminin zemin kat ölçüleri ve beton dayanımının bilinmesi gereklidir. Öncelikle her bir kolon ve perde elemanın kesme dayanımı (etriye katkısı ihmal edilerek) hesaplanır. Zemin katta her bir eleman için hesaplanan bu değerler toplanarak tüm bina taban kesme dayanımı (V_c) elde edilmiş olur. Yöntemde dolgu duvarların yatay yük taşıma kapasitesine katkısını da içeren bina dayanım değeri (V_{yw}) hesaplanmaktadır. Yöntem bu değerden bina akma dayanımını tanımlamaktadır. Binanın güvenlik derecesini belirlemek için kapasite-talep oranı olarak adlandırılacak "Temel Kapasite İndeksi (Basic Capacity Index)" (BCPI) hesaplanır (Denk. 3.1).

$$BCPI = V_{yw}/V_{y\text{önetmelik}} \quad (3.1)$$

Binada bulunabilecek düzensizliklerin bina kapasitesine etkilerinin de değerlendirilebilmesi için “Kapasite İndeksi (Capacity Index)” (CPI) Denk. (3.2) ile tanımlanmıştır. CPI (Kapasite İndeksi) değerleri binaların güvenlik derecesini göstermektedir.

$$CPI=CA \times CM \times BCPI \quad (3.2)$$

Denklemden CA, yapısal düzensizlik katsayısı, CM, inşaa kalitesi katsayısıdır. CA değeri çeşitli düzensizlikler için belirli değerlerin, ideal durumu ifade eden 1 değerinden çıkarılması ile Denk. (3.3)’te görüldüğü gibi hesaplanmaktadır.

$$CA=1-(CAS+CASC+CAP+CAF) \quad (3.3)$$

CAS, yumuşak kat katsayısı, CASC, kısa kolon katsayısı, CAP, burulma düzensizliği katsayısı, CAF, düşeyde süreksizlik düzensizliği katsayısıdır (Çizelge 3.1).

Çizelge 3.1. İnşaa kalitesi katsayısı değerleri (Yakut, 2004)

Katsayı	Değer		
	Kötü	Orta	İyi
CM	$1 - 0,55 \times (1 - CA)$	$1 - 0,55 \times (1 - CA) / 3$	1

Sonuç olarak, daha büyük CPI değerine sahip binalar daha güvenli olarak kabul edilmektedir. Bu yöntemde; CPI sınır değerinin her bir bina stoku için ayrı olarak belirlenmesi gerektiği önerilmekle birlikte kabaca 1 ya da 2 değerinin kullanılabileceğini ifade edilmiştir.

3.2.3. P25 yöntemi

Bal ve ark. (2007) tarafından geliştirilen P25 Yönteminde; yapıda mevcut kolon, perde ve dolgu duvar boyutları, rijitlikleri, taşıyıcı sistem düzeni, bina yüksekliği, yönetmelikte tanımlanan çeşitli yapısal düzensizlikler, malzeme ve zemin özellikleri gibi parametreler üzerinden hesap yapılarak bulunan P₁ temel yapısal puanı ile birlikte binanın değişik göçme modlarını da göz önüne alan toplam 7 (yedi) adet göçme puanı hesaplanmaktadır. Son olarak, bu puanların birbirleri ile etkileşimini, yapısal ve çevresel özellikleri, binanın bulunduğu bölge ve deprem verilerini de göz önüne alan bir P sonuç puanı belirlenmektedir. Elde edilen P_{sonuç} puanının az, orta veya yüksek riskli bölgeye düşmesi durumuna göre yapının göçme riski hakkında ya kesin bir bilgi edinilmekte ya da finansal verilere göre belirlenen bir kararsızlık bandı içine düşmesi halinde, kapsamlı inceleme yapılarak gerekirse yıkılması veya güçlendirilmesi önerilmektedir. Önerilen hızlı değerlendirme yönteminde binanın P_{sonuç} puanını hesaplayabilmek için öncelikle söz konusu binanın P₁, P₂,..., P₇ olmak üzere yedi ayrı göçme riskini temsil eden 7 farklı değerlendirme puanı hesaplanır. Bu risklerin birbirleri ile etkileşime girip girmediklerini saptamak için her P_i puanı için belirlenen ağırlık çarpanı

da dikkate alınarak P_w ağırlıklı ortalama puanı hesaplanır. Daha sonra, P_i puanlarının en küçüğü olan P_{\min} puanı için P_w ağırlıklı ortalama puanına bağlı olarak P_i göçme kriterlerinin birbirleri ile etkileşimini temsil eden bir β çarpanı bulunur. Ayrıca, binanın önem derecesini, bölgenin depremsellik derecesini, binanın hareketli yük katsayısını ve binanın oturduğu arazinin topografyasını temsil eden bir α çarpanı ile düzeltme yapılır. Elde edilen $P_{\text{sonuç}}$ performans puanının değerine göre söz konusu binanın yıkılma potansiyeli olup olmadığı konusunda bilgi edinilir.

P_1 temel yapısal puanı hesaplanırken dikkate alınan yapısal düzensizlik katsayıları Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Yapısal düzensizlik katsayıları (f_i)

Katsayı	Tanım	Risk Seviyesi		
		Yüksek	Az	Yok
f_1	Burulma Düzensizliği	0,90	0,95	1,0
f_2	Döşeme Süreksizliği	0,90	0,95	1,0
f_3	Düşey Doğrulukta Süreksizlik	0,65-0,70	0,90	1,0
f_4	Kütle Düzensizliği	0,90	0,95	1,0
f_5	Korozyon Mevcudiyeti	0,90	0,95	1,0
f_6	Ağır Cephe Elemanları	0,90	0,95	1,0
f_7	Asma Kat Mevcudiyeti	0,90	0,95	1,0
f_8	Katlarda Seviye Farkı veya Kısmi Bodrum	0,80	0,90	1,0
f_9	Beton Kalitesi	$f_9 = (f_c/20)^{0,5}$		
f_{10}	Zayıf Kolon Kuvvetli Kiriş	$f_{10} = [(I_x+I_y)/2I_b]^{0,15} \leq 1,0$		
f_{11}	Etriye Sıklığı	$f_{11} = 0,60 \leq (10/s)^{0,25} \leq 1,0$		
f_{12}	Zemin Sınıfı	0,90	0,95	1,0
		(Z4 için)	(Z3 için)	(Z2, Z1 için)
f_{13}	Temel Tipi	0,80-0,90	0,95	1,0
		Tekil Temel	Sürekli Temel	
f_{14}	Temel Derinliği	0,90	0,95	1,0
		(1m'den az)	(1-4m arası)	(4m'den fazla)

Çizelge 3.2.’deki değerlerin P_0 puanı ile arka arkaya çarpılması sonucu P_1 puanı Denk. (3.4)’teki şekilde elde edilir:

$$P_1 = P_0 \cdot \left(\prod_{i=1}^{14} f_i \right) \quad (3.4)$$

P_1 temel yapısal puanın yanı sıra P_2 Kısa Kolon Puanı, P_3 Yumuşak Kat ve Zayıf Kat Puanı, P_4 Çıkmalar ve Çerçeve Süreksizliği Puanı, P_5 Çarpışma Puanı, P_6 Sıvılaşma Potansiyeli Puanı, P_7 Toprak Hareketleri Puanları da hesaplanarak P_{\min} puanı bulunur. Bulunan bu puanın binanın ve yörenin özelliklerine göre ayrıca bir α çarpanı ile düzeltilmesi gerekmektedir. α çarpanı; bina önem


katsayısı I, deprem bölgesine gören tayin edilen efektif ivme katsayısı A_0 , hareketli yük çarpanı n ve topografik konum katsayısı t göz önüne alınarak Denk. (3.5)'deki formülle hesaplanır.

$$\alpha = (1/I).(1,4-A_0).[1/(0,4n+0,88)].t \quad (3.5)$$

Topoğrafik t katsayısının nominal değeri; bina düzlükte ise $t = 1,0$ 'dir. Bu katsayı, incelenen binanın bir tepenin üstüne kurulu olması durumunda $t = 0,7$ ve dik bir yamaçta kurulu olması durumunda ise $t = 0,85$ değeri alınarak hesaplar yapılmaktadır.

Binanın sonuç performans puanı daha önce hesaplanan 7 adet P_i puanının ağırlıklı olarak birbirleri ile etkileşimleri yolu ile belirlenmektedir. Bunun için önce P_i puanları içinden P_{\min} puanı saptanır ve ağırlık katsayısı olarak $w = 4$ ile çarpılır. Diğer P_i puanları söz konusu P_i puanının ağırlık puanları (w_i) ile çarpılarak ağırlıklı ortalama puanı P_w belirlenir. Ağırlıklı ortalama puanı P_w kullanılarak Şekil (3.28) yardımı ile bir β düzeltme çarpanı elde edilir.

$$P_w = \sum(w_i.P_i) / \sum w_i \quad (3.6)$$



Şekil 3.28. β katsayısının değişimi

Yukarıda hesaplanan α ve β çarpanları yardımı ile binanın performansını belirleyen $P_{\text{sonuç}}$ puanı ise Denk. (3.7) aracılığıyla elde edilir.

$$P_{\text{sonuç}} = \alpha.\beta.P_{\min} \quad (3.7)$$

Burada P_{\min} birbirinden bağımsız olarak hesaplanan ve yukarıda tarif edilen 7 adet P_i değerlendirme puanı arasından en küçüğüdür. Bulunan bu P_i değerlendirme puanına göre yapıların detaylı yapısal analiz ile değerlendirmeye alınıp alınmayacaklarına karar verilmektedir. Bu bağlamda bulunan bu değerlendirme puanı aşağıda ifade edilen aralıklarla değerlendirilerek binanın mevcut durumuna karar verilir.

- $0 < P \leq 24$ aralığında ise bina göçer.
- $25 < P \leq 34$ aralığında ise bina için detaylı analiz gerekir.
- $35 < P \leq 100$ aralığında ise binanın göçmeyeceği tespitleri yapılır.

3.2.4. RVS (Sucuođlu) yöntemi

Sucuođlu ve ark. (2007) tarafından geliştirilen RVS Yöntemi, normal betonarme binalarda 8 kattan daha az katlı olmak üzere iki seviyeli sismik risk değerlendirme yöntemidir. Binaların değerlendirme aşamasında kat adedi, binanın görünüş kalitesi, yumuşak kat etkisi, ağır çıkmalar, kısa kolon etkisi, çarpışma etkisi, topoğrafik etkiler, sismik risk ve yerel toprak koşulları belirlenir. Kat adedine ve sismik risk bölgelerine (deprem bölgelerine) göre bir taban puan belirlenir. Performans puanını belirlemek için binanın hangi sismik risk bölgesinde (deprem bölgesinde) olduğunu belirtmek gerekir. Taban Puanlar (BS) ve Güvenlik Puanları (VS) çizelgesinde temel puanlar (BS) ve güvenlik puanları (VS) okunur. Binada gözlemlenen güvenlik etkilerinin puanları dikkate alınarak Denk. (3.8)'e göre binanın performans puanı hesaplanır.

$$PS = BS + \sum_{i=1}^n VSM_i * V_{si} \quad (3.8)$$

Denklemden PS, performans puanını, BS, taban puanını, VSM_i güvenlik puan çarpanlarını, V_{si} ise güvenlik puanını göstermektedir. Performans puan aralığı $0 < Ps \leq 30$ arasında ise en yüksek öncelik gerektiren binalar olarak tanımlanır ve detaylı analiz yapılması gerekir. Performans puan aralığı $Ps > 100$ olan binalar ise en düşük öncelikli değerlendirme gerektirir.

3.2.5. RYTEİE-2019 yöntemi

Türkiye'de mevcut betonarme bina stokunun hızlı ve ekonomik şekilde değerlendirilmesi amacıyla Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2019) tarafından yayımlanan ve kullanılan bir yöntemdir. Birinci derece değerlendirme yönteminde binanın dışından ve kısmen içinden belirlenen, deprem davranışını etkileyen taşıyıcı sistem türü, kat adedi, mevcut durum ve görünen kalite, yumuşak kat/zayıf kat, düşeyde düzensizlik, ağır çıkmalar, planda düzensizlik/burulma etkisi, kısa kolon etkisi, yapı nizamı/çarpışma etkisi, tepe/yamaç etkisi, deprem tehlikesi ve zemin sınıfı parametrelerinden faydalanılır. İlgili parametreler yardımıyla her bir bina için performans puanı (PP) hesaplanır ve bulunan puanlar büyükten küçüğe doğru sıralanır. Böylece bölgesel risk öncelikleri belirlenmiş olur. Bina performans puanı (PP) Denk. (3.9) kullanılarak hesaplanır. Denklemden binanın bulunduğu yerin deprem bölgesine ve toplam kat adedine bağlı olarak TP taban puanı ve yapısal taşıyıcı sistem puanı (YSP) ilgili yönetmelikte verilen çizelgelerden alınır.

$$PP = TP + \sum_{i=1}^n O_i * O_{pi} + YSP \quad (3.9)$$

Denk. (3.9)'da verilen olumsuzluk parametre değeri (O_i) ve olumsuzluk parametre puanı (OP_i) görünen kalite dışındaki tüm olumsuzluk parametreleri için "var" veya "yok" şeklinde tespitler yapılır. Bu tespitlere karşılık gelen olumsuzluk parametre değerleri (O_i) "var" ve "yok" durumları için sırasıyla 1 ve 0 alınır. Görünen kalite değerlendirmesi "iyi" ise olumsuzluk parametre değeri (O_i) 0, "orta" ise 1 "kötü" ise 2 alınır. Toplanan veriler değerlendirilerek her bina için bir performans puanı hesaplanır. Hesaplanan performans puanları büyükten küçüğe doğru sıralanır. Bu şekilde hesaplanan puanların dağılımı kullanılarak bölgeler arasında risk önceliği belirlenebilir. Bu yöntemle binalar için sadece deprem tehlikesi açısından öncelik sıralaması belirlenir.

3.2.6. DURTES yöntemi

Bu yöntem, İstanbul Üniversitesi Mühendislik Fakültesi, İnşaat Mühendisliği Bölümünde görev yapan Gürsoy ve ark. (2003) tarafından İstanbul ili Bakırköy ilçesinde bulunan yapı stokunun deprem güvenilirliğinin analizine yönelik yapılan çalışmanın sonuçları kullanılarak geliştirilmiştir. Çalışmada yaklaşık 10.000 bina üzerinde yapı durum tespitiyle ilgili detaylı inceleme yapılmış ve elde edilen veriler yardımı ile hızlı değerlendirme yapan bir bilgisayar yazılımı geliştirilmiştir (Çelik ve ark., 2003).

Bu çalışmada öncelikle incelenen binanın matematiksel esasa göre değerlendirilmesi için gerekli olan bilgiler belirlenmiş ve bu doğrultuda bilgilerin yer aldığı bir anket formu hazırlanmıştır. Bu anket formundaki bilgilerin yerinde doldurulması ve bu bilgilerin söz konusu algoritmayı kullanan DURTES (DURum TESpit) adlı bilgisayar yazılımına aktarılması sayesinde binaların maruz kalacağı deprem yükü, taşıyabileceği deprem yükü ve mukavemeti gibi özellikler çok hızlı bir şekilde belirlenmektedir.

Hızlı Durum Tespit Yöntemi (DURTES) binanın malzeme özelliğini de göz önüne alarak, farklı özelliklerde olsalar bile maruz kaldıkları yüklere karşılık, belirli bir alan için sahip olması gerekli olan, yapısal eleman büyüklüklerini belirleyerek bir katsayı elde edilmekte (K_1 : mukavemet puanı) ve bu katsayıya göre binalar gruplandırılmaktadır. Her binanın mevcut durumuna göre ayrı bir puan verilmektedir (K_2 : kusur puanı). K_1 katsayısı yönetmeliklerdeki kriterlere göre, K_2 katsayısı ise yapının mevcut durumunu göz önüne alan yaklaşık olarak 100 adet parametreye göre belirlenmektedir. Söz konusu parametrelere karşılık gelen puanın verdiği sonuçlar, kesin çözüm yöntemlerinin sonuçları ile kıyaslandıkça kalibre edilmektedir. Bu kesin çözüm yöntemleri ile kıyaslama örnekleri çoğaldıkça programın verdiği sonuçlar gerçeğe daha da yakınlaşmaktadır. DURTES Yönteminde göreceli durum tespit puanı kullanılarak incelenen binanın risk seviyesi belirlenmektedir. Göreceli durum tespit puan aralığı; $(GDP) \geq 75$ ise düşük risk seviyesi, 50-75 aralığında ise orta risk seviyesi, 25-50 aralığında ise yüksek risk seviyesi, 0-25 aralığında ise çok yüksek risk seviyesinde olduğu tespit edilir.

3.2.7. AURAP yöntemi

Topçu ve ark. (2017) tarafından geliştirilen AURAP Yöntemi, Hızlı Durum Tespit Yöntemi'nin (DURTES) temelleri üzerinde kurulmuş ve geliştirilmiştir. Bu yöntem ile çerçevesel binalar için mevcut yönetmeliklerde yer alan prosedürlere göre daha hızlı, daha düşük maliyetli ve daha güvenilir bir değerlendirme imkânı sağlanmıştır.

AURAP metodu genel manada 2 aşamadan oluşmaktadır. Bu aşamalar: Yapısal Güvenlik Faktörü (SSF) ve Göreceli Kat Puanının (RBS) belirlenmesidir. Yapı için hesaplanan SSF ve RBS puanları dikkate alınarak Nihai Değerlendirme Puanı (FAS) hesaplanması neticesinde mevcut yapının deprem vb. etkilere karşı dayanıklılığı ortaya konulur.

Yapısal Güvenlik Katsayısı (SSF) Hesabı:

SSF'nin belirlenmesinin ilk aşaması Denk. (3.10)'da verilen taban kesme kuvvetinin (V_b) hesaplanmasıdır. Daha sonra Denk. (3.11)'de verilen yaklaşık bina ağırlığı (W) ile etkili yer ivme katsayısı (A_0) belirlenir. Bina önem katsayısı (I), spektral ivme değeri $S(T)$ ve yapısal sistem davranış katsayısı (R) perde duvarların varlığına bağlı olarak belirlenir. Binanın döşeme türüne göre, herhangi bir kattaki ölü yük yaklaşık olarak belirlenir. Bina türü yapılar için hareketli yük $q = 2 \text{ KN/m}^2$ ve hareketli yük azaltma katsayısı $n=0,3$ olarak alınır. A_i herhangi bir kattaki toplam kat alanını, N kat sayısını, H_N bina yüksekliğini, T_A ve T_B ise binanın bulunduğu yere bağlı olarak belirlenen karakteristik spektrum periyotlarını belirtmektedir. C_T katsayısı ise, momente dayanıklı çerçeve sistemler için 0,075 olarak alınan bir katsayı olarak hesaplarda kullanılmaktadır.

$$V_b = W.A_0.I.S(T)/R \quad (3.10)$$

$$W = \sum_{i=1}^N [(G_i + nq_i)A_i] \quad (3.11)$$

$$T_1(s) = C_T.H_N^{3/4} \quad (3.12)$$

Binanın kesme dayanımı kapasitesi x ve y doğrultusunda V_x ve V_y olarak ayrı ayrı hesaplanır. V_x ve V_y 'den küçük olan değer, yapının taban kesme dayanım kapasitesi (V_c) olarak hesaplarda dikkate alınır.

$$V_x = 0,65.f_{ct}.A_{cx} \quad (3.13)$$

$$V_y = 0,65.f_{ct}.A_{cy} \quad (3.14)$$

$$V_c = \min (V_x, V_y) \quad (3.15)$$

$$f_{ct} = f_c/15 \quad (3.16)$$

Betonun çekme dayanımı Denk. (3.16)'da verildiği üzere ampirik olarak yaklaşık beton basınç dayanımınının 1/15'i mertebesinde hesaba katılır.

X doğrultusundaki toplam etkili taban kesme alanı A_{cx} ve y doğrultusundaki toplam etkili taban kesme alanı Denk. (3.17) ve Denk. (3.18) aracılığıyla hesaplanır.

$$A_{cx} = \sum A_c + \sum A_{swx} \quad (3.17)$$

$$A_{cy} = \sum A_c + \sum A_{swy} \quad (3.18)$$

Yukarıdaki denklemlerde $\sum A_c$ kritik kat enine kesitindeki toplam kolon alanını, $\sum A_{swx}$ ve $\sum A_{swy}$ ise kritik kat enine kesitindeki x ve y doğrultularına paralel duvar alanlarını ifade etmektedir.

Yukarıdaki denklemler kullanılarak elde edilen sonuçlar ışığında yapısal güvenlik katsayısı (SSF) Denk. (3.19) aracılığıyla hesap edilir.

$$SSF = V_c/V_b \quad (3.19)$$

Görelî Bina Puanı (RBS) Hesabı:

AURAP metodunun en önemli aşamalarından biri de Görelî Bina Puanının (RBS) hesaplanmasıdır. Başlangıçta yapının RBS değeri 100'e eşittir. Ancak düzensizlikler ve yapısal kusurların yapıda var olması durumunda 0 ile 1,0 arasında değişen cezalandırma katsayıları aracılığıyla RBS puanı azaltılarak Denk. (3.20) uyarınca hesaplanır.

$$RBS = 100 \cdot \prod_{i=1}^N P_i \quad (3.20)$$

Yukarıdaki denklemde yer alan P_i ifadesi düzensizliklere bağlı olarak belirlenen cezalandırma katsayılarıdır. Bunlar planda oluşan düzensizlikler, düşeyde oluşan düzensizlikler ve yapısal problemlerden (çerçeve süreksizliği, güçlü kiriş zayıf kolon problemi, kısa kolon problemi, köşe kolon problemi gibi) kaynaklı kusurlara ilişkin katsayılarıdır. Düzensizlikler ve yapısal kusurlara ek olarak binanın yaşı, temel tipi, döşeme tipi, binanın konumu (binalara merkezden veya köşeden bağlı olma durumu), çarpışma etkisi, kiriş ve kolonların kapalı bir çerçeve sürekliliği sağlayıp sağlamaması, bu cezalandırma katsayılarının belirlenmesindeki parametreleri ifade etmektedir.

Çerçeve süreksizliği problemi oldukça yaygın bir problem olması sebebiyledir ki geçmiş depremlerde yapıların ağır hasar görmesine hatta çökmesine sebep olmuştur. Ağır çıkma olan yapılarda kolonlar arasında kapalı süreklilik sağlayacak kirişlerin olmaması çerçeveli bir yapı davranışının sergilenmesine engel olarak yukarıda belirtilen probleme sebebiyet vermektedir. O yüzden AURAP metodunda Sürekli Çerçeve Oranı (CFR) yaklaşımı da hesaplara dâhil edilmiştir. Bu oran 0,5'ten büyük ise binanın çerçeve davranışını tatmin edici bir şekilde sergilediği düşünülür.

Yukarıda elde edilen tüm veriler ışığında Nihai Değerlendirme Puanı (FAS) Denk. (3.21) aracılığıyla hesaplanır.

$$FAS = SSF.RBS \quad (3.21)$$

Yukarıdaki denklem aracılığı ile hesaplanan FAS değeri 50 puanın altında ise yapı yüksek riskli, 50 ile 150 puan arasında ise orta riskli, 150'den büyük ise düşük risklidir. Eğer sonuç puanı 150 puanın altında ise mevcut yönetmelikler uyarınca yapı detaylı olarak incelenmelidir.

3.2.8. PERA yöntemi

İlki ve ark. (2014) tarafından geliştirilen PERA Yöntemi riskli binaların bölgesel dağılımının belirlenmesi için ikinci aşama değerlendirmesi (binanın dışarıdan belirlenen parametrelerine ek olarak, malzeme dayanımları, eleman boyutları gibi özellikleri göz önüne alınır) ve bina bazında risk değerlendirmesi için de bir ön değerlendirme aracı olarak kullanılabilir. PERA Yönteminde binanın zemin katı deprem yükleri açısından kritik kat olarak kabul edilmektedir. Bu kata ait kolon boyutlarının, kolon net yüksekliklerinin ve kolon konumlarının da bilinmesi gerekmektedir. Metotta ilk olarak yönetmeliğe göre taban kesme kuvveti hesaplanmaktadır. Taban kesme kuvveti hesabında Denk. (3.22) kullanılmaktadır.

$$V_t = \lambda W S_{(T)} A_0 I \quad (3.22)$$

(Burada; λ : Eşdeğer deprem yükü azaltma katsayısı = 0,85, W: Bina birim ağırlığı 12 kN/m² kabulü ile hesaplanan toplam bina ağırlığı, $S_{(T)}$: Spektrum Katsayısı, A_0 : Etkin yer ivmesi katsayısı (ABYYHY-1998 ve DBYBHY-2007 yönetmeliklerinde yer alan deprem bölgesine bağlı etkin yer ivme katsayısı), I: Bina önem katsayısı, (Konut türü yapılarda 1 alınmaktadır).)

PERA Yönteminde, kolon kesme kuvvetleri hesaplanırken Denk. (3.23)'den yararlanılmaktadır.

$$V = V_t \frac{(I/Ln^3)}{\Sigma(\frac{I}{Ln^3})} \quad (3.23)$$


(Burada; I: Eylemsizlik momenti L_n : Net kolon yüksekliğini ifade etmektedir.)

Kolon momentlerinin hesabında Muto Yönteminde yer alan Denk. (3.24) kullanılmaktadır.

$$M = V L y \quad (3.24)$$

(Burada; V: Kolon kesme kuvveti, L: Zemin kat yüksekliği, y: Rijitlik oranına bağlı katsayıyı ifade etmektedir.) (L ve y değerleri Muto (1956) Yönteminden yararlanılarak bulunmaktadır. Giriş

rijitliklerinin Denk. (3.27)'de verilmiş olan hesabında çatlamış kesit kabulü yapılmaktadır. Kolonların yapı içindeki konumlarına köşe, kenar ve orta kolon olmalarına göre kolon rijitlikleri Denk. (3.28) ile hesaplanabilmektedir.) (Şekil 3.29).



Şekil 3.29. Kolonların yapı içindeki konumları

$$k = \frac{k_2}{k_c} \quad \text{Kenar Kolon} \quad (3.25)$$

$$k = \frac{k_1 + k_2}{k_c} \quad \text{Orta Kolon} \quad (3.26)$$

$$k_{1,2} = \frac{I_{300\text{mm} \times 600\text{mm}}}{L = 5\text{m}} \quad (3.27)$$

$$k_c = \frac{I}{L} \quad (3.28)$$

PERA Yönteminde, İlki ve ark. (2014) incelemiş olduğu farklı binalardan elde ettikleri verilere göre, kirişlerin boyutları 300 mm × 600 mm ve boyları 5 metre kabul edilmektedir. Hesaplanan rijitlik oranı k'ye göre her bir kat için söz konusu yöntem dâhilinde verilen y değerleri bulunabilmektedir.

Smith Yönteminde ise büküm noktaları kolon yüksekliğinin ortasında olduğu kabul edilmektedir. Bundan dolayı Smith Yönteminde bu işlemler ve Çizelge okumaları yapılmadan kolon momentlerinin hesabında Denk. (3.29) kullanılmaktadır.

$$M = VL0.5 \quad (3.29)$$

PERA metodunda kolonlara etkiyen düşey yüklerden gelen eksenel yükleri hesaplamak için kolonun yapı içindeki durumuna göre bir kod sistemi uygulanmaktadır. Bu kod sistemine göre, X doğrultusundaki ilk ve son akslarda bulunan kolonlarda x1 ve x2, Y doğrultusunda ilk ve son akslarda bulunan kolonlarda y1 ve y2, iç aks kolonları ise O olarak adlandırılmaktadır. Kesişim noktasında bulunan kolonlara ise buldukları akslara göre x1y1, x2y1 gibi isimler verilmektedir.

Kolonlara etkiyen düşey yüklerden gelen eksenel yükleri hesaplamak için Denk. (3.30) kullanılmaktadır.

$$N_{G+Q} = \frac{s}{\Sigma s} W \quad (3.30)$$

(Burada; N_{G+Q} : Kolonlara etkiyen düşey yüklerden gelen eksenel yükler s : Kolonların bina içindeki konumlarına göre kodları, W : Toplam bina yükünü ifade etmektedir.)

PERA Yönteminde dış kolonlara etkiyen deprem kaynaklı eksenel yükler taban dönme momenti ile hesaplanmaktadır. İç kolonlara etkiyen depremsel eksenel yükler ihmal edilmektedir. Dış kolonlara etkiyen yükleri hesaplamak için Denk. (3.31) ve Denk. (3.32) kullanılmaktadır.

$$TDM = V_t \frac{2H_n}{3} \quad (3.31)$$

(Burada; V_t : Taban kesme kuvveti, H_n : Bina yüksekliğini ifade etmektedir.)

$$T = -C = \frac{TDM - \Sigma M_{ci}}{L_{taban}} \quad (3.32)$$

(Burada; M_c : Kolonlardaki toplam moment, L_{taban} : Bina dış aksları arası uzaklığı ifade etmektedir.)

Depremden gelen kolon eksenel yükleri yöntemde belirtildiği şekliyle hesaplanmaktadır. Kolonların moment kapasitelerinin hesaplanmasında eksenel yük moment kesişim eğrisi kullanılmaktadır. Yöntemde, İlki ve ark. (2014) tarafından Kocaeli, Van ve İstanbul'da 149 bina ve 912 kolon kesitinin incelenmesi sonucunda elde edilen istatistiksel veriler doğrultusunda donatı dağılımı basınç ve çekme bölgelerinde $0,40\rho$, gövde bölgesinde ise $0,20\rho$ olarak kabul edilmiştir (ρ : donatı oranı).

Kolonlarda oluşabilecek maksimum kesme kuvveti V_e hesaplanırken Denk. (3.33)'ten yararlanılmaktadır. Orta kolonlarda $M_{üst}$ hesaplanırken Denk. (3.34) kenar kolonlarda ise Denk. (3.35) kullanılmaktadır.

$$V_e = \frac{(M_{üst} + M_{alt})}{L_n} \quad (3.33)$$

(Burada; $M_{üst} = \min(M_k, \text{kolon moment kapasitesi})$ M_{alt} = Kolon moment kapasitesini ifade etmektedir.)

$$M_{üst} = (M_{rj} + M_{ri})/2 \quad (3.34)$$

$$M_{üst} = M_{ri}/2 \quad (3.35)$$

PERA metodunda kabul edilen 30cm*60cm boyutlarındaki ve 0,005 donatı oranındaki kirişlerse S220 ve S420 için pozitif moment kapasitesi 120 ve 210 kNm, negatif moment kapasitesi 160 ve 290 kNm olarak hesaplanmıştır (İlki ve ark., 2014). PERA Yönteminde kolonun kesme dayanımı, V_r , TS-500-2000 (2000)'e göre Denk. (3.36) kullanılarak hesaplanmaktadır.

$$V_r = 0,8V_c + V_w \quad (3.36)$$

(Burada; V_c : Beton katkısı, V_w : Kesme donatısı katkısı olarak ifade edilmektedir.)

Betonarme bir kesitin kesmede çatlama dayanımı, daha kesin hesaba gerek duyulmadığı durumlarda Denk. (3.37) kullanılarak hesaplanmaktadır.

$$V_{cr} = 0,65f_{ctd}b_wd \left(1 + \gamma \frac{N_d}{A_c} \right) \text{ (MPa)} \quad (3.37)$$

(Burada; f_{ctd} : Beton aksel çekme dayanımı, b_w : Kolon genişliği, d : Kolon faydalı yüksekliği, γ : katsayı (aksel basınç durumunda 0,07, aksel çekme durumunda ise -0,3 alınmalıdır.) N_d : Aksel yük (Çekmede ve basınçta pozitif alınmalıdır.) A_c : Kesit alanını ifade etmektedir.)

Kesme dayanımının etriyelerin katkısı Denk. (3.38) ile hesaplanmaktadır.

$$V_w = \frac{A_s}{s} f_{ywm} d \text{ (MPa)} \quad (3.38)$$

(Burada; A_s : Kesme donatısı toplam kesit alanı, s : Etriye aralığı f_{ywm} : Enine donatı akma dayanımı, d : Kolon faydalı yüksekliğini ifade etmektedir.)

PERA Yönteminde, yönetmeliğe uygun olarak yapı düzensizlikleri de incelenmektedir (A1: Burulma düzensizliği, A2: Döşeme süreksizlikleri, A3: Planda çıkıntılar bulunması, B1: Zayıf kat, B2: Yumuşak kat, B3: Düşey eleman süreksizliği). Yöntemde, düzeltme azaltma katsayıları adı altında yönetmelikte geçen her bir düzensizlik için kodlar bulunmaktadır. Bu kodlar Japon standartlarına, mevcut betonarme binaların sismik kapasite değerlendirilmesine göre tanımlanmıştır. Mevcut binalarda birden fazla düzensizlik olması durumunda düzensizliklere tanımlanan katsayılar çarpılmaktadır.

PERA metodunda, yapı elamanlarının hasar seviyesi kolon etki/kapasite oranları ile belirlenmektedir. Deprem yönetmeliğinde yer alan sınırlara göre yapı elamanlarının hasar seviyesi tespit edilmektedir. (DBYBHY-2007, Şekil 2.1). PERA Yönteminde yapı elemanlarındaki hasarlar tespit edilirken ayrıca kesme değerleri de kontrol edilmektedir. Eğer $V_e > V_r$ ve $r_{1i} > 1$ ise göçme bölgesi olarak değerlendirilmektedir.

Eğer $V_e < V_r$ ve $r_{1i} < 1$ ise etki/kapasite oranına ve sargılama olup olmadığına bakılarak belirlenmeye çalışılmaktadır. Kesme kuvveti kontrolünde Denk. (3.39) eğilme kontrolünde ise Denk.

(3.40) kullanılmaktadır. Metotta, etriye aralığının 10 cm veya daha az olması durumunda sargılama var kabul edilmektedir (İlki ve ark., 2014) (Bölüm 2.1. DBYBHY-2007, Çizelge 2.3).

$$r_1 = \frac{V_e}{V_r} \quad (3.39)$$

$$r_2 = \frac{M_e}{M_r} \quad (3.40)$$

PERA Yönteminde görelî kat öteleme hesabı da deprem yönetmeliğine paralel olarak yapılmaktadır. Yöntemde zemin kattaki görelî kat ötelemeleri hesabında Denk. (3.41) kullanılmaktadır. D parametresi ise Denk. (3.42)'de görüldüğü üzere zemin kattaki görelî kattaki kolonların konumuna göre Muto Yöntemiyle bulunmaktadır. Betonun elastisite modülü TS-500-2000 (2000)'e göre Denk. (3.44)'ten hesaplamaktadır. Öteleme oranı hesaplandıktan sonra Çizelge 2.4 (Bölüm 2.1, DBYBHY-2007) kullanılarak hasar sınırları tespit edilmektedir.

$$\delta = \frac{V_t L^2}{12 E_c \Sigma D_i} \quad (3.41)$$

(Burada; δ / L : Öteleme oranı, E_c : Betonun elastisite modülünü ifade etmektedir.)

$$D = a k_c \quad (3.42)$$

Temele ankastre bağı kolonlarda

$$a = \frac{0,5 + \bar{k}}{2 + \bar{k}} \quad (3.43)$$

$$E_c = 14000 + 3250 \sqrt{f_{ckj}} \quad (3.44)$$

(Burada; f_{ckj} : j günlük betonun karakteristik silindir dayanımını ifade etmektedir.)

Yapı elemanlarındaki hasarlar etki/kapasite oranlarına ve görelî kat ötelemelerine göre tespit edilmektedir. PERA Yönteminde elde edilen verilere göre incelenen betonarme binaların risk durumları ile ilgili sonuçlara varılmaktadır. PERA metodunda 4 farklı kombinasyonda +X, - X, +Y, -Y sonuçlar elde edilmektedir. Yöntemde incelenen kombinasyonlarda zemin kattaki yapı elemanlarında herhangi bir hasar yok ise yapı az riskli, herhangi bir kolonda veya birden fazla kolonda yüksek risk var ise bina yüksek risk taşımaktadır sonucuna varılmaktadır (İlki ve ark., 2014).

3.2.9. Japon sismik indeks yöntemi

Japonya Bina Afet Önleme Kurumu (1990) tarafından geliştirilen Japon Sismik İndeks Yöntemi; betonarme çerçeve, perde-çerçeve veya sadece perdelerden oluşan taşıyıcı sisteme sahip

bina türü yapılara uygulanabilmektedir ve söz konusu yapı türlerindeki binaların deprem güvenilirliğinin hızlı bir şekilde tahmin edilmesi amacı ile kullanılmaktadır. Yöntem giderek daha gerçekçi sonuç veren ve daha çok zaman alan üç aşamadan oluşmakla birlikte, bu tez çalışmasında sadece hızlı değerlendirme yöntemi ve detaylı yapısal çözümleme sonuçlarının karşılaştırılması amaçlanmadığından yöntemin yalnızca birinci aşaması ile ilgili bilgi verilmiştir.

Bu yöntemin 30 yaşın üzerindeki, büyük fiziksel bozuklukları bulunan, malzeme dayanımı düşük olan veya taşıyıcı sistemi alışılmıştan dışında olan binalarda kullanılması önerilmemektedir (JBDPA, 1990). Değerlendirmenin ilk aşaması yapının taşıyıcı sisteminin, yaşının ve fiziksel durumunun incelenmesini içerir. Bu incelemeler sonucunda elde edilen veriler ışığında yapının deprem performansını gösteren indeks I_s belirlenir. I_s indeksi ile yapı için göz önüne alınması uygun olan karşılaştırma indeksi I_{so} mukayese edilerek yapının deprem güvenilirliği tahmin edilir. Bu karşılaştırma tüm kritik katlar ve iki asal deprem doğrultusu için ayrı ayrı uygulanır. $I_s > I_{so}$ olduğunda yapının depreme karşı güvenli olduğuna, tersi durumda ise yapının deprem güvenilirliğinin belirsiz olduğu sonucuna ulaşılır. Ayrıca, $I_s / I_{so} < 0,4$ ise yapının depreme karşı güvenilirliğinin ayrıntılı incelemesinin yapılması gerekmektedir. Burada deprem güvenilirliği yapının hiç hasar görmeyeceği anlamını değil, toptan göçmenin meydana gelmeyeceği anlamını taşımaktadır (İlki ve ark., 2003).

Karşılaştırma indeksi Denk. (3.45) ile hesaplanabilir. Bu denklemde E_s ana karşılaştırma indeksinin birinci düzey inceleme için 0,80 alınması önerilmektedir. Z bölge katsayısı deprem riskinin yüksek olduğu bölgelerde genel olarak 1,0 olarak alınmakla birlikte, binanın bulunduğu bölgenin depremselliğine göre azaltılabilir, ancak Z katsayısının hiçbir zaman 0,70'ten küçük alınmaması önerilmektedir. G zemin katsayısı, zemin büyütmesi oluşturacak nitelikte zemin durumu ve topografik koşullarla ilgili olan büyüklüktür. G katsayısı zemin durumuna göre 1,0 ile 1,10 arasında değişen değerler alabilmekte olup zemin koşulları kötüleştikçe G katsayısının değeri de büyümektedir. U kullanım katsayısı yapının önem derecesi ve kullanımıyla ilgilidir. Her yapı için yapının önem derecesi ve deprem sonucu oluşabilecek etkilerin boyutu da göz önüne alınarak özel olarak belirlenmektedir. Deprem sırasında insanların barınak olarak kullanacağı yerler, tehlikeli madde depoları gibi yapılarda U katsayısının 1,25, konut ve benzeri yapılarda 1,0 olarak alınması önerilmektedir.

$$I_{so} = E_s \cdot Z \cdot G \cdot U \quad (3.45)$$

Performans indeksi I_s Denk. (3.46) ile hesaplanabilir. Bu denklemde E_o ana yapısal performans indeksi, S_D yapının fiziksel özelliklerine ve geometrisine göre belirlenen katsayı, T ise zamana bağlı oluşan etkilere göre belirlenen katsayıdır. E_o indeksinin hesaplanmasında kullanılmak üzere yapıdaki düşey taşıyıcı elemanlar kolon, kısa kolon ve perde olarak üç grupta incelenmektedir. Taşıyıcı eleman net yüksekliğinin, kesit derinliğine oranı 2'den büyük olan düşey taşıyıcı elemanlar

((h_0/D) > 2) kolon, taşıyıcı eleman net yüksekliğinin, kesit derinliğine oranı 2'den küçük veya eşit olan düşey taşıyıcı elemanlar ((h_0/D) < 2) kısa kolon olarak adlandırılmaktadır (İlki ve ark., 2003).

$$I_{s0} = E_o \cdot S_D \cdot T \quad (3.46)$$

Denk. (3.46)'da kullanılan E_o indeksinin hesaplanma yöntemi yapıda kısa kolon bulunması veya bulunmaması durumlarında farklılık göstermektedir. E_o yapıda kısa kolon bulunmaması durumunda Denk. (3.47) ile bulunması durumunda ise Denk. (3.48) ile hesaplanmaktadır. Bu denklemlerden, bodrum kat hariç olmak üzere toplam kat adedini, i göz önüne alınan katı, C_w perdelerin taşıma gücünü, C_c kolonların taşıma gücünü, F_w perde sünekliğine bağlı katsayıyı ifade etmekte olup bu denklemde 1,0 olarak göz önüne alınabilir. a_1 , yer değiştirme uyum katsayısını belirtmekte olup genelde 0,70 alınır; ancak $C_w = 0$ ise a_1 1,0 alınmalıdır. C_{sc} kısa kolonların taşıma gücünü, F_{sc} kısa kolon sünekliğine bağlı katsayıyı ifade etmekte olup 0,80 olarak alınabilir. a_2 ve a_3 kısa kolon bulunması durumunda sırasıyla perdeler ve kolonlar için yer değiştirme uyum katsayılarını belirtmekte olup $a_2 = 0,70$ ve $a_3 = 0,50$ alınabilir (İlki ve ark., 2003).

- Yapıda kısa kolon bulunmaması durumunda;

$$E_o = \left(\frac{n+1}{n+i} \right) (C_w + a_1 \cdot C_c) \cdot F_w \quad (3.47)$$

- Yapıda kısa kolon bulunması durumunda;

$$E_o = \left(\frac{n+1}{n+i} \right) (C_w + a_2 \cdot C_w + a_3 \cdot C_c) \cdot F_{sc} \quad (3.48)$$

Yapıda kısa kolon varsa E_o indeksi hesaplanırken kısa kolonların taşıma gücünü göz önünde bulunduran Denk. (3.48) ile kısa kolonların taşıma gücünü ihmal eden Denk. (3.47)'den büyük olan alınmalıdır. Ancak, kısa kolonlarda meydana gelebilecek göçme sonucunda, toptan göçme veya can güvenliğini tehdit eden bir durumun oluşması olası ise, E_o indeksi her zaman Denk. (3.48) ile hesaplanmalıdır.

Perdelerin taşıma gücü C_w Denk. (3.49) ile hesaplanabilir. Bu denklemde A_{w1} iki tarafından başlıklı perdelerin toplam enkesit alanını (cm^2), A_{w2} bir taraftan başlıklı perdelerin toplam enkesit alanını (cm^2), A_{w3} başlıksız perdelerin toplam enkesit alanını (cm^2), f_{cd} beton basınç dayanımını (kgf/cm^2), W göz önüne alınan kat üzerindeki bina ağırlığını (kgf) ifade etmektedir.

Kolonların taşıma gücü Denk. (3.50) ile hesaplanabilir. Bu denklemde A_{c1} eleman net yüksekliği / kesit derinliği < 6 olan kolonların toplam enkesit alanını (cm^2), A_{c2} ise eleman net yüksekliği / kesit derinliği > 6 olan kolonların toplam enkesit alanını (cm^2) göstermektedir. Kısa

kolonların taşıma gücü ise Denk. (3.51) kullanılarak hesaplanabilir. Bu denklemde A_{sc} kısa kolonların toplam enkesit alanını (cm^2) ifade eder.

$$C_w = \frac{(30A_{w1} + 20A_{w2} + 10A_{w3}) \cdot f_c}{200 \cdot W} \quad (3.49)$$

$$C_c = \frac{(10A_{c1} + 7A_{c2}) \cdot f_c}{200 \cdot W} \quad (3.50)$$

$$C_{sc} = \frac{15A_{sc} \cdot f_c}{200 \cdot W} \quad (3.51)$$

S_D katsayısı plandaki düzensizlikler, bodrum katın varlığı, plandaki boyutların oranı, kat yüksekliklerindeki düzensizlik, genişleme derzlerinin aralıkları, yumuşak katın varlığı, plandaki büyük boşluklar ve dış merkezlik gibi özellikler dikkate alınarak hesaplanmaktadır. Örneğin, yapı yaklaşık simetrik bir plana sahipse hesaplarda $S_D = 1,0$, L, T, U gibi simetrik olmayan bir plana sahipse $S_D = 0,90$ olarak göz önüne alınabilir. Planda uzun boyut / kısa boyut < 5 ise $S_D = 1,0$ bu oran 5 ile 8 arasında ise $S_D = 0,80$ olarak göz önüne alınabilir (İlki ve ark., 2003).

Zamana bağlı etki katsayısı T, binadaki deformasyonlar, perde ve kolonlardaki çatlaklar, sıva ve kaplamalardaki çatlaklar, binanın yaşı ve yangın geçirmiş olup olmadığı gibi etkenler göz önüne alınarak belirlenmektedir (JBDPA, 1990).

3.2.10. Kanada sismik tarama yöntemi

Kanada Ulusal Araştırma Birliği (1993) tarafından yayımlanan ilkeler doğrultusunda önerilen yöntem çok aşamalı bir incelemenin ilk aşaması olarak düşünülmekte ve incelenen bina grubundaki her bir binanın deprem riskinin sayısal olarak ön değerlendirmesini içermektedir. Sayısal değerlendirme yapıldıktan sonra öncelik sırasına göre daha kapsamlı bir çalışma mutlaka yapılmalıdır. Değerlendirmeye tabi tutulacak binaların seçilmesi de önemli bir aşamadır. Mühendislik hizmeti almamış, hasar görebilirliği yüksek, sünek olarak tasarlanmadığı ve imal edilmediği düşünülen çerçeve türü binalara öncelik verilebilir. Mimari çizim ve mühendislik projelerine ulaşılabilecek binalar bir sonraki değerlendirmeye bırakılabilir (Altınar, 2008).

Bu yöntemin kullanıcıları mühendisler, mimarlar, bina sahipleri, acil müdahale yöneticileri olabilmektedir. Yönteminin kullanıcılarının farklı disiplinlerden olması geliştirilen formların daha itinayla hazırlanmasını, teknik terimlere gereğinden fazla yer verilmesine sebep olmuştur. Hızlı değerlendirme yöntemlerini içeren el kitapçıkları değerlendiricilerin kolaylıkla kullanabileceği tarzda hazırlanmıştır. Değerlendirme yapacak ekibin başında devamlı olarak bilgi alabilecekleri yapı ve deprem mühendisliği konularında tecrübeli bir yol göstericinin bulunması esastır. Böylece daha güvenilir değerlendirme yapılması sağlanmış olur (Altınar, 2008).

İncelemeye konu olacak binalarda olabildiğince bilgi toplamak doğru karar verebilmek için esastır. Bu amaçla söz konusu yöntem için hazırlanmış formda bu bilgilere yer verilmektedir. Her bir bilgi sayısal bir değere karşılık gelmektedir. Binanın adresi, posta numarası, bina kat adedi, yapının imal yılı, projelendirme yılı, toplam bina kullanım alanı, bina adı, değerlendirme yapanın künyesi, değerlendirme tarihi, binanın çevresiyle ilişkisini gösteren şematik bir plan, binanın tipik bir fotoğrafı, var ise tipik kat planı, yapımda kullanılan taşıyıcı sistemin malzemesi (betonarme, çelik, yığma, ahşap vb.) taşıyıcı sisteme zaman içerisinde yapılan müdahale, bozulmalar, beklenen maksimum yer ivmesi ve hızını içeren bölgenin deprenselliği (A), zemin koşulları (B), taşıyıcı sistem türü (C), döşeme sistem türü (D), binada var olan düzensizlikler (E), binayı kullanan insan sayısına bağlı bir önem katsayısı (F) gibi parametrelere değerler verilerek sayısallaştırılmış ve yapısal indeks (SI) olarak Denk. (3.52)'deki şekliyle tanımlanmıştır (Altınar, 2008).

$$SI = A. B. C. D. E. F \quad (3.52)$$

Binanın genel durumu (G) ve yapısal olmayan bileşenleri (H) de değerlendirmeye alınmak suretiyle hesaplanan yapısal olmayan indeks (NSI) katsayısı Denk. (3.53)'te verilmiştir.

$$NSI = B. F. G. H \quad (3.53)$$

Yapısal ve yapısal olmayan indekslerden sismik öncelik indeksine (SPI) Denk. (3.54) ile dönüşüm yapmak suretiyle geçilebilir.

$$SPI = SI + NSI \quad (3.54)$$

Bu sayısal verilerin dışında, incelenen bina ile ilgili değerlendirmeler söz konusu yöntemde kullanılan dokümana işlenebilmektedir.

A, B, C, D, E, F, G, H katsayılarının alabileceği sayısal değerlerin üst ve alt limitleri değerlendirme sonuçları bakımından önemlidir. Deprensellik faktörü olarak da tanımlanabilecek A değeri 1-5 aralığında değişebilmektedir; yüksek A değerleri daha riskli bölgelere karşılık gelmektedir.

Zemin koşulu faktörü B kaya ya da çok sağlam zeminlerde 1,0, sıvılaşma potansiyeli yüksek, taşıma kapasitesi düşük zeminlerde 1,5 değerini almaktadır.

Taşıyıcı sistemle ilgili olan C katsayısı, depreme dayanıklı tasarım ilkeleri doğrultusunda tasarlanmış sünek sistemlerde düşük, tersi sistemlerde yüksek değerler almaktadır; örneğin 1,0 sünek olarak detaylandırılmış bir taşıyıcı sisteme karşı gelirken 3,5 gevrek sistemlere karşılık gelmektedir. Bu değerlerin taşıyıcı sistem davranış katsayısına benzerlikler gösterdiği söylenebilir; ancak farklı bir yorumu vardır (Altınar, 2008).

Döşeme sistemine bağlı olan D katsayısı 1-2 arasında değişmektedir; hafif ve diyafram özelliği gösterebilen döşeme sistemlerinde bu katsayı düşüktür. Yapısal düzensizlikle ilgili bir faktör olan E hasar görebilirliği çok etkilemekte olup binada her bir düzensizliğe karşı gelen puanlar vardır; tanımlanan düzensizlikler ilgili deprem yönetmeliklerinden farksızdır. Bunlar: düşeyde düzensizlik, burulma düzensizliği, kısa kolon, yumuşak kat, çekiçleme etkisi, bina taşıyıcı sistemindeki proje dışı önemli değişiklikler ve değişik türde yapısal hasar oluşumlarıdır. Yapısal düzensizliklerin çoğunun mimari proje kaynaklı olduğu bilinmekte, uygun mimari projelerde düzensizliklerin en aza indirilmesi olanaklı olmaktadır. Binada gözlenen her bir düzensizliğe 0,3-1,0 arasında değişen puan verilmekte olup en düşük değer düşeyde düzensizlik, komşu binalarla çarpışması, sistemde yapılan değişiklikler ve hasara, en büyük /olumsuz katsayı ise yumuşak kat oluşumuna verilmektedir.

E değerinin üst bir limitte sınırlandırılması da önerilmekte ve gerçekte böylesi bir binanın önemli sorunlar içerdiğide bilinmektedir.

Binanın önemi ile ilgili olan F katsayısı binada yaşayanların sayısına (N) bağlıdır; içinde 10 kişiden az insan barındıran binalarda (düşük önem düzeyi) 0,7, 10-300 arasında (normal önem düzeyi) 1,5, 300-3000 arasında (okul ve yüksek önem düzeyi) 2,0, 3000'den fazla (deprem sonrası hemen kullanım ve çok yüksek önem düzeyi) olması durumunda 3,0 alınmaktadır. Binanın bugünkü durumunu simgeleyen G katsayısı ise en iyi/sorunsuz durumda 1,0, çok sorunlu durumda 4,0 ile hesaba katılmaktadır.

Yapısal olmayan faktörler H ile gösterilmekte, çıkış ve kaçış yollarını etkileyecek bina dışında serbestçe bulunan parapetler ve bacalar ile bina içindeki yığma kâgir duvarları, mekanik ve elektrik ekipmanları ile raflar gibi bileşenlerden oluşmaktadır. Var olan her bir iç ve dış bileşen için 1,0 puan verilmektedir (Altın, 2008).

Bina ile ilgili inceleme tamamlandıktan sonra bir sonraki aşama için elde edilen sayısal sonuçların değerlendirilmesi yapılır. Bu aşamada öncelikli olarak hesaplanan indekse göre bir sıralama yapılmaktadır. İndeksin yüksek olması önceliğin yüksek olması gerektiği anlamına gelmektedir.

Öncelik sıralamasında üç indeksten (SI, NSI, SPI) biri kullanılabilmesi gibi binanın ve bölgenin depremselliği dikkate alınarak yalnızca biri de seçilebilir. Örneğin, deprem riski düşük bölgelerde yapısal olmayan hasarların değerlendirilmesi durumunda o binanın değerlendirilme kapsamına alınıp alınmaması kararı verilmelidir. Öncelik sıralamasında kullanılacak sınır değerlerin belirlenmesi bina için kullanılacak bütçeyi doğrudan etkilediğinden, güç olmakla birlikte, varsayılan bazı değerlere karşı geldiği öncelik düzeyleri ile şöyledir (Altın, 2008):

- SI ya da NSI 1,0~2,0 Yeterli Deprem Güvenliği (YDG)
- SPI <10 Düşük Öncelikli Binalar (DÖB)
- SPI 10~20 Orta Öncelikli Binalar (OÖB)
- SPI >20 Yüksek Öncelikli Binalar (YÖB)

- SPI >30 Çok Tehlikeli Binalar (ÇTB)

Pek çok faktörü dikkate alan bu yöntemin başarıya ulaşması nitelikli kişilerce doğru/güvenilir veri toplamaya doğrudan bağlıdır. Güvensiz verilerle karşılaşıldığında ya çekince ile kullanılmalı ya da hiç kullanılmamalıdır. Bina ile ilgili bir projeye ulaşılmadığında güvensizlik doğurabilecek veriler binanın projelendirme ve yapım yılı, kat alanları, zemin koşulları, yapısal olmayan ve bir deprem sırasında düşmesi/göçmesi olası bileşenler olarak sıralanabilir. Belirsizliklerin çok olması durumunda güvenli tarafta kalacak seçimlerin yapılması önerilmektedir (Çelik ve ark., 2007).

Mevcut betonarme binalar için yukarıda detaylı olarak anlatılan hızlı tarama yöntemlerinde dikkate alınan ve alınmayan parametreler Çizelge 3.3'te detaylı olarak verilmiştir.

Çizelge 3.3. Hızlı sismik değerlendirme yöntemlerinde dikkate alınan parametreler

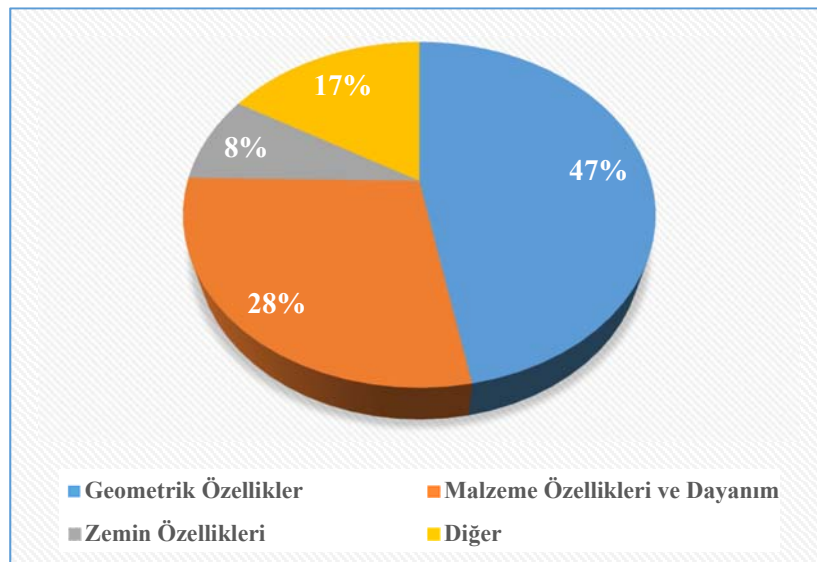
Parametreler	Betonarme Binalar için Hızlı Sismik Değerlendirme Yöntemleri									
	1. Kademe Yöntemler				2. Kademe Yöntemler					
	FEMA 154	KANADA	SUCUOĞLU (RVS)	RYTEİE 2019	JAPON	YAKUT	P25	AURAP	PERA	DURTES
Olası Deprem İvmesi-En Büyük Yer Hızı (PGV)	✓	✓	✓	✓	X	X	✓	✓	✓	✓
Kat Sayısı	✓	X	✓	✓	X	X	X	✓	✓	✓
Bina Yüksekliği	X	X	✓	X	✓	X	✓	✓	X	✓
Binanın Yaşı	✓	X	X	X	X	X	X	✓	X	✓
Proje Varlığı	X	X	X	X	X	X	X	X	X	✓
Burulma Düzensizliği (A1)	✓	✓	X	✓	✓	✓	✓	✓	✓	✓
Döşeme Süreksizlikleri (A2)	✓	✓	X	✓	✓	✓	✓	✓	✓	✓
Planda Çıkıntılar Bulunması (A3)	✓	✓	X	✓	✓	✓	X	✓	✓	✓
Paralel Olmayan Yapı Elemanları Varlığı (A4)	X	✓	X	X	X	X	X	✓	X	X
Zayıf Kat (B1)	✓	✓	X	✓	✓	✓	✓	✓	✓	✓
Yumuşak Kat (B2)	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Taşıyıcı Sistem Düşey Elemanlarının Süreksizliği (B3)	✓	✓	X	✓	X	✓	✓	✓	✓	✓
Kütle Düzensizliği	X	X	X	X	X	X	✓	X	X	X
Korozyon Varlığı	X	X	X	X	X	X	✓	X	✓	✓
Yönetmelik Öncesi/Sonrası Durumu İnşa	✓	X	X	X	X	X	X	X	X	✓
Ağır Cephe Elemanları Varlığı	X	✓	✓	✓	X	✓	✓	✓	X	✓
Kısa Kolon Varlığı	X	✓	✓	✓	✓	✓	✓	✓	X	✓
Asma Kat Varlığı	X	X	X	X	X	X	✓	X	X	✓
Bodrum Kat Varlığı	X	X	X	X	✓	X	X	X	X	✓
Katlarda Seviye Farkı veya Kısmi Bodrum	X	X	X	✓	X	X	✓	X	X	✓
Beton Kalitesi/Sınıfı	X	X	X	X	X	✓	✓	X	✓	✓
Beton Çekme Dayanımı (f_{ct})	X	X	X	X	X	✓	X	✓	✓	X
Zayıf Kolon Kuvvetli Kiriş Varlığı	X	X	X	X	X	X	✓	✓	✓	✓
Etriye Sıklığı	X	X	X	X	X	X	✓	X	✓	✓
Zemin Sınıfı	✓	✓	✓	✓	✓	X	✓	✓	✓	✓
Temel Tipi	X	X	X	X	X	X	✓	✓	X	✓
Temel Derinliği	X	X	X	X	X	X	✓	X	X	X
Döşeme Tipi	X	✓	X	X	X	X	X	✓	X	✓
Çıkıntılar ve Çerçeve Süreksizliği	X	✓	✓	X	X	X	✓	✓	X	✓
Bitişik Nizam-Çekiçleme-Çarpışma	X	✓	X	✓	X	X	✓	✓	X	✓

Sıvılaşma Potansiyeli	X	✓	X	X	X	X	✓	X	X	X
Toprak Hareketleri	X	✓	X	X	X	X	✓	X	X	X
Hareketli Yük Çarpanı	X	X	X	X	X	X	✓	✓	X	X
Topografik Konum Katsayısı (Zemin Eğim Durumu)	X	X	✓	✓	X	X	✓	✓	X	✓
Bina Ağırlığı	X	X	X	X	X	X	X	✓	✓	✓
Bina Önem Katsayısı	X	✓	X	X	✓	X	X	✓	X	✓
Spektral İvme Değeri S(T)	X	X	X	X	X	X	X	✓	✓	X
Yapısal Sistem Davranış Katsayısı (R)	X	X	X	X	X	X	X	✓	X	✓
Yapısal Sistem Türü	X	✓	X	✓	✓	X	X	X	X	X
Herhangi Bir Kattaki Toplam Kat Alanı (Ai)	X	X	X	X	X	X	X	X	✓	X
Bina Kesme Dayanım Kapasitesi (Vx-Vy)	X	X	X	X	X	X	X	✓	X	X
Toplam Etkili Taban Kesme Alanı (Acx-Acy)	X	X	X	X	X	X	X	✓	X	X
Kritik Kat Enine Kesitindeki Toplam Kolon Alanı ($\sum A_c$)	X	X	X	X	X	X	X	X	✓	X
Kritik Kat Duvar Alanları ($\sum A_{swx}-\sum A_{swy}$)	X	X	X	X	X	X	X	X	✓	X
Kritik Kattaki Toplam Perde Alanı	X	X	X	X	X	X	X	X	X	X
Köşe Kolon Problemi	X	X	X	X	X	X	X	✓	X	X
Bina Görsel Kalitesi/İnşa Kalitesi	X	✓	✓	✓	✓	✓	✓	X	X	X
Kat Alanı	X	X	X	X	X	X	X	X	X	✓
Toplam Kesit Alanı (Kolon+Perde+Duvar) (X-Y)	X	X	X	X	X	X	X	X	X	✓
Yapıdaki En Büyük Açıklık	X	X	X	X	X	X	X	X	X	✓
Ortalama Kat Ağırlığı	X	X	X	X	X	X	X	X	X	✓
Dilatasyon Varlığı ve Yeterliliği	X	X	X	X	✓	X	X	X	X	✓
Boyuna Donatı Sınıfı	X	X	X	X	X	X	X	X	✓	✓
Enine Donatı Sınıfı	X	X	X	X	X	X	X	X	✓	✓
Binanın Simetriklik Durumu	X	✓	X	X	✓	X	X	X	X	✓
Eleman Kesme Dayanımı (Vci)	X	X	X	X	X	✓	X	X	X	X
Bina Taban Kesme Dayanımı (Vc)	X	X	X	X	X	✓	X	X	X	X
Bina Akma Dayanımı (Vy)	X	X	X	X	X	✓	X	X	X	X
Zemin Kattaki Kolon Boyutları	X	X	X	X	X	X	X	X	✓	X
Zemin Kattaki Kolon Uzunluğu	X	X	X	X	X	X	X	X	✓	X
Kolon Konumları (X-Y)	X	X	X	X	X	X	X	X	✓	X
Toplam Bina Plan Alanı	X	X	X	X	X	X	X	X	✓	X
Taban Kesme Kuvveti (Vb)	X	X	X	X	X	X	X	X	✓	X
Kolon Kesme Dayanımı (V)	X	X	X	X	X	X	X	X	✓	X
Katlar Arası Ötelenme	X	X	X	X	X	X	X	X	✓	X
Devrilme Momenti	X	X	X	X	X	X	X	X	✓	X
Kolon Momenti (Me)	X	X	X	X	X	X	X	X	✓	X
Kolon Moment Taşıma Kapasitesi (Mr)	X	X	X	X	✓	X	X	X	✓	X
Moment Taşıma Kapasitesine Karşılık Gelen Normal Kuvvet (Nk)	X	X	X	X	X	X	X	X	✓	X
Kolon ve Kirişlerin Eğilme Kapasitesine Karşılık Gelen Kesme Kuvveti (Ve)	X	X	X	X	X	X	X	X	✓	X
Kesme Dayanım Kapasitesi (Vr)	X	X	X	X	X	X	X	X	✓	X
Dayanım Azaltma Faktörü (R)	X	X	✓	X	X	X	X	X	X	X
Tek Dereceli Sistemin Maksimum Plastik Deformasyonu (Δ_p)	X	X	✓	X	X	X	X	X	X	X
Titreşim Periyodu (T)	X	X	✓	X	X	X	X	X	X	X
Kat Yüksekliği Düzensizliği	X	X	X	X	✓	X	X	X	X	X
Dış Merkezlik	X	X	X	X	✓	X	X	X	X	X

Zamana Bağlı Etki Katsayısı (T)	X	X	X	X	✓	X	X	X	X	X
Perdelerin Taşıma Gücü (C _w)	X	X	X	X	✓	X	X	X	X	X
Kolonların Taşıma Gücü (C _c)	X	X	X	X	✓	X	X	X	X	X
Perde Sünekliği Katsayısı (F _w)	X	X	X	X	✓	X	X	X	X	X
Kısa Kolon Taşıma Gücü (C _{sc})	X	X	X	X	✓	X	X	X	X	X
Yer Değiştirme Uyum Katsayıları (a ₁ ,a ₂ ,a ₃)	X	X	X	X	✓	X	X	X	X	X
İki Tarafından Başlıklı Perdelerin Toplam Enkesit Alanı (A _{w1})	X	X	X	X	✓	X	X	X	X	X
Bir Tarafından Başlıklı Perdelerin Toplam Enkesit Alanı (A _{w2})	X	X	X	X	✓	X	X	X	X	X
Başlıksız Perdelerin Toplam Enkesit Alanı (A _{w3})	X	X	X	X	✓	X	X	X	X	X

Not: Çizelgede yer alan ✓ işareti söz konusu yöntemde belirtilen parametrenin hesap esaslarında dikkate alındığını, X işareti ise parametrenin dikkate alınmadığını göstermektedir.

Mevcut betonarme binaların hızlı sismik değerlendirilmesi için yaygın olarak kullanılan Çizelge 3.3'te verilmiş olan 10 farklı yöntemde ele alınan başlıca kıstaslar 85 parametre altında toplanmıştır. Bu parametrelerden 40 tanesi geometrik özellik parametresi, 24 tanesi malzeme özellikleri (beton ve donatı özellikleri ve tasarımı) ve dayanımı içeren parametre, 7 tanesi zemin özellikleri-yerel şartları kapsayan parametre, 14 tanesi ise yapısal sistem davranışı katsayısı-hareketli yük çarpanı-bina önem katsayısı vb. katsayıları ve diğer üç başlık altında yer almayan parametreleri içermektedir. Şekil 3.30'da söz konusu parametrelerin, belirtilen dört sınıf dâhilinde yüzdesel dağılımını gösteren grafik verilmiştir. Şekil 3.30'da görüldüğü üzere geometrik parametreler hızlı sismik değerlendirme yöntemleri içinde önemli bir paya sahiptir.



Şekil 3.30. Hızlı sismik değerlendirme yöntemlerindeki parametrelerin sınıflandırılması

Bu tez çalışması kapsamında kullanılan Ön Eğitimli KSA ile tespit edilen 3 parametreden: ağır çıkma varlığı; Çizelge 3.3'te verilen tüm hızlı sismik değerlendirme yöntemlerinde, bitişik nizamlılık durumu; Kanada, RYTEİE-2019, P25, AURAP ve DURTES yöntemlerinde, eğimli arazi

varlığı durumu ise; Sucuođlu (RVS), RYTEİE-2019, P25, AURAP ve DURTES yöntemlerinde dikkate alınmaktadır. Buradan da anlaşılacağı üzere tez çalışmasında tespiti yapılan söz konusu parametreler, hızlı sismik değerlendirme yöntemlerinde sıkça kullanılan ve önem arz eden geometrik özelliklerdendir.



4. YAPAY ZEKA TANIMI VE TARİHSEL GELİŞİMİ

Kavram olarak 1950’li yıllarda ortaya çıkan yapay zekânın literatürde ortak bir tanımı bulunmamaktadır. Günümüzde yapay zekâ, insanlar tarafından zeki davranış olarak nitelendirilen birtakım faaliyetlerin makineler tarafından yapılmasını inceleyen bir bilgisayar bilimleri dalıdır. Yapay zekâ hakkında literatürde geçen tanımları incelersek John McCarthy’e (2019) göre yapay zekânın hedefi “insan gibi davranış gösteren makineler geliştirmektir”. Nabiyev (2018) ise yapay zekâyı, “bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği” biçiminde ifade etmiştir. Yapay zekânın çalışma alanları ve tarihsel gelişimi Şekil 4.1’de görülmektedir.



Şekil 4.1. Yapay zekâ gelişim süreci


Russell ve Norvig’in (2010) çalışmasına göre ise yapay zekâ, “akıllı varlıkları anlamak ve bunları taklit ederek karar verme sürecini basit, hızlı ve verimli hale getirmek için tasarlanmış bir mantık sistemidir.”

Yapay zekâ, insanlar gibi düşünen ve hareket eden aynı zamanda akıllı davranışların otomasyonu ile ilgilenen bir kavramdır. Yapay zekâ hakkındaki tanımlamalar dört gruba ayrılmaktadır. Bunlar, insan gibi düşünen makineler (thinking humanly), insan gibi davranan makineler (acting humanly), rasyonel düşünen makineler (thinking rationally), rasyonel davranan makinelerdir (acting rationally) (Russell ve Norvig, 2010).

4.1. Yapay Sinir Ağları

YSA, yapısal ve kavramsal olarak insan biyolojik sinir hücresinden ilham alarak birbirlerine bağlı yapay sinirlerden oluşmaktadır. Doğrusal olmayan bir modeldir ve bir girdi seti ve tek bir çıktı içermektedir (Nabiyev, 2016). İnsan beyinde yer alan sinir ağları karmaşık öğrenme ve yorumlama

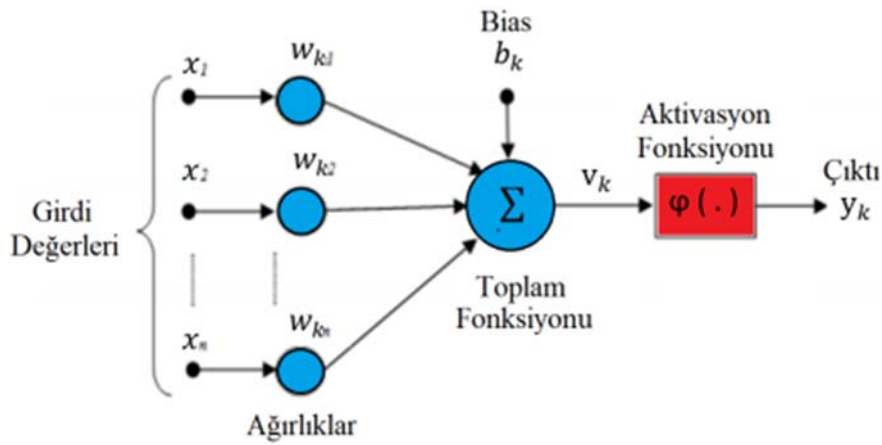
yeteneğine sahiptir. 1943'te McCulloch ve Pitts bu karmaşık sistemi matematiksel olarak taklit ederek yapay zekânın ve MÖ'nün temelini oluşturmuşlardır (Ertel, 2009). YSA, kontrol ve sistem tanımlama, görüntü ve ses tanıma, tahmin ve kestirim, arıza tespiti gibi alanlarda kullanılmaktadır (Pirim, 2011). Özetle, YSA bir insan beyninin işleyişini ve basit gözlemlerle yeni kurallar oluşturma yeteneğini taklit etmektedir. Aksonlar kendilerine gelen bilgiyi (sinapsis) işlemiden geçirerek diğer sinir hücrelerinin dentritlerine iletir (Şekil 4.2).



Şekil 4.2. Biyolojik sinir ağı (Anonim, 2022)


Bu prensip ile birlikte çok katmanlı sinir ağlarını açıklamak gerekirse, sinir hücreleri akson uçları (sinapsis) ve dentrit ile birbirine bağlıdır. Bu YSA'da $f(x)$ fonksiyonun sonucunda çıkardığı y değeridir.

Şekil 4.3'te yapay sinir hücresi görülmektedir. Buradaki fonksiyonları inceleyecek olursak, sinyalin girişi X vektörleri ile gösterilmiştir. Girdi değeri, diğer adı ile sinyal değeri belirtilmiş olan ağırlıklar ile çarpılarak veri akışı gerçekleşir.



Şekil 4.3. Yapay sinir hücresi şeması (Calp, 2022)

Şekil 4.4'te tek katmanlı bir YSA'nın temel yapısı görülmektedir. Daireler YSA'nın düğümlerini diğer adı ile nöronlarını göstermektedir. Basit sinir ağı modelinde, 3 katman bulunmaktadır. Bunlar giriş katmanı, gizli katman (ara katman) ve çıkış katmanıdır. Giriş katmanında girdinin piksel değerleri belirlenir. Gizli katmanda görselin renk ve piksel dağılımları incelenir. Çıkış katmanında ise modele daha önce öğretilmiş olan görsellerin özellikleri ile karşılaştırma yaparak sonuç vermektedir.



Şekil 4.4. Tek katmanlı bir yapay sinir ağının temel yapısı (Güzel, 2022)

Çizelge 4.1'de yukarıdaki anlatılan durumun bir arada görülmesi için hazırlanılmış ve sinir sistemi elemanları ile YSA sistemi bileşenleri arasındaki benzerlik ve karşılıklarının ne olduğu gösterilmektedir.

Çizelge 4.1. Sinir sistemi ile YSA yapısının benzerlikleri

Sinir Sistemi	Yapay Sinir Ağları Sistemi
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi (Çekirdek)	Aktivasyon Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

Şekil 4.3'te bulunan simgeler ve isimlendirmelerin tanımları şu şekildedir. Burada; X; girdiler olup, nöronlara gelen verilerdir. (Şekil 3.2'de X_1 , X_2 ve X_n olmak üzere toplam k girdi verisi bulunmaktadır.) W; ağırlıklar olup nöronlar arasındaki bağlantıları matematiksel olarak ifade eden katsayı değeridir. Her X değeri için ağırlık hesabı yapılmaktadır ve her bir girdi değerinin kendine özel olan bir ağırlığı vardır. YSA'ya tanıtılan veriler arttıkça ve değiştikçe ağırlık değerleri de değişecektir. Toplam fonksiyonu ise terim birleştirme fonksiyonu olarak da tanımlanmakta olup

yapay sinir hücresine gelen girdilerin ağırlıklar ile çarpılarak burada toplanması neticesinde, sinir hücresinin net girdisi elde edilmektedir. YSA hücrelerinin her zaman ve her koşulda toplama fonksiyonları ile aynı olması zorunlu olmamakla birlikte, her sinir hücresi diğerlerinden farklı çeşitli birleştirme fonksiyonuna sahip olabilmektedir. Örneğin; yapay sinir hücresine gelen girdilerin ağırlıklar ile çarpılarak bulunan değerler de birbirleri ile çarpılması fonksiyonuna çarpım fonksiyonu denilmektedir. ϕ (.) aktivasyon fonksiyonu olarak tanımlanmakta olup, sinir hücresine gelen net girdiyi işleyerek, bu girdinin sonucunda çıktı değerini belirler. y_k ; hücrenin çıktısı olarak tanımlanmakta olup, aktivasyon fonksiyonu sonrasında çıkan değeri ifade etmektedir.

4.1.1. Aktivasyon fonksiyonları

Aktivasyon fonksiyonlarına transfer fonksiyonları da denilmektedir. Birleştirme fonksiyonu sonucu ile sağlanan net girdiyi belirli bir işlemde geçirerek, çıktıyı belirlemek bu fonksiyonun yaptığı işlemler ile gerçekleştirilmektedir. Çeşitli aktivasyon fonksiyonları bulunmakla birlikte, en doğru sonuca ulaşabilmek için seçilecek olan aktivasyon fonksiyonunda deneme yanılma ile elde edilen sonuçların karşılaştırılması ile en doğruya yakın olduğu düşünülen aktivasyon fonksiyonu seçilmelidir. Denemeler, tamamıyla kullanıcının tecrübesine göre farklı yollarda ve yöntemlerle olabilmektedir. Bu noktada önemli olan husus, diğer tercihlere göre en doğru olabilecek sonuca ulaşmaktır.


YSA mimarilerinde kullanılan çeşitli aktivasyon fonksiyonları bulunmakta olup, en çok kullanılanlar ise aşağıda belirtilmiştir.

- Doğrusal Aktivasyon Fonksiyonu
- Sigmoid Aktivasyon Fonksiyonu
- Tanjant Hiperbolik Aktivasyon Fonksiyonu

Her ne kadar aktivasyon fonksiyonlarının en çok kullanılan üç tanesi yukarıda ifade edilen fonksiyonlar olsa da farklı çeşitleri de bulunmaktadır. Diğer kullanılan transfer fonksiyonlar ise Adım (Step/Basamak), Eşik, Hiperbolik, RELU (Rectified Linear Unit), Sızıntı (Leaky) RELU, Softmax, Swish (A Self-Gated/Kendinden Geçitli) vb. fonksiyonlardır.

Doğrusal Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonunu tanımlarsak, YSA hücresinde hesaplanan net giriş değeri, hücrenin çıkış değeri olarak kabul edilmektedir. Şekil 4.5'te doğrusal aktivasyon fonksiyonu grafiği gösterilmektedir.



Şekil 4.5. Doğrusal aktivasyon fonksiyonu

Doğrusal aktivasyon fonksiyonunu matematiksel olarak ifade etmek istersek $y=kx$ şeklinde tanımlamak mümkündür. Burada, k sabit bir sayıyı ifade etmektedir. Ayrıca, birleştirme fonksiyonu Denk. (4.1) ve Denk. (4.2)'deki şekliyle ifade edilmektedir.


$$F(\text{Net}) = \text{Net} \quad (4.1)$$

$$(\text{Net} = \sum_{i=1}^n X_i * W_i) \quad (4.2)$$

Sigmoid Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu 0 ile 1 arasında değerler üretmektedir. Sigmoid aktivasyon fonksiyonunun türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olmasından dolayı uygulamada en çok kullanılan aktivasyon fonksiyonudur. Aşağıdaki formül ile ifade edilmektedir. Şekil 4.6'da sigmoid aktivasyon fonksiyonu gösterilmektedir. Ayrıca, birleştirme fonksiyonu Denk. (4.3) ile verilmiştir. (e sayısı veya Euler sayısı; matematik, doğal bilimler ve mühendislikte önemli yeri olan sabit bir reel sayı olup yaklaşık değeri 2,718'dir.)

$$F(\text{Net}) = \frac{1}{1 + e^{-x}} \quad (4.3)$$




Şekil 4.6. Sigmoid aktivasyon fonksiyonu

Tanjant Hiperbolik Aktivasyon Fonksiyonu

Bu aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonunun farklı bir çeşidi olarak tanımlanmaktadır. Sigmoid aktivasyon fonksiyonunda çıktı değerinden farklı olarak negatif değerler de üretilmektedir. Tanjant hiperbolik aktivasyon fonksiyonunda çıktı değerleri -1 ile 1 arasındadır. Şekil 4.7’de tanjant hiperbolik aktivasyon fonksiyonu gösterilmektedir. Ayrıca, birleştirme fonksiyonu Denk. (4.4) ile verilmiştir.

$$F(\text{Net}) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.4)$$



Şekil 4.7. Tanjant hiperbolik fonksiyonu

4.1.2. Yapay sinir ağları kullanım alanları

YSA'nın neredeyse tüm disiplin ve bilim alanlarında kullanılabilmesi mümkündür. Mühendislik, fen, matematik, tıp, işletme, finans vb. gibi çok çeşitli alanlarda işlemin ve tahminin girdiği hemen her alanda YSA yardımıyla çözülmüş problemler bulunmakta, karşılaşılan karmaşık ve zor olan sorunlar aşılmaktadır. YSA'nın kullanım alanları: sınıflandırma, tahminde bulunma, desen-örüntü tanıma, fonksiyon yaklaşımında bulunma ve optimizasyon sağlama olarak sıralanabilir (Yetkin, 2014).

4.1.3. Yapay sinir ağlarının özellikleri

YSA doğrusal olmayan, dalgalı, karmaşık problemlerin çözümüne ilişkin daha az hata toleransına sahip sonuçlar ve çözümler üretebilmekte ve mevcut problemin çözümüne dair eldeki verileri kullanmakta ve bu veriler ile işlem içindeki gizli olan bağlantıları ve durumları ortaya çıkarmaktadır. Buna, ağırlık fonksiyonu öğrenmesi işlemi de denilmektedir. Öğrenme işlemi olan işlemler, YSA oluşturulurken hücrelerin arasında bulunan ve bu kısımda kullanılacak olan ağırlıkların bulunmasıdır.

YSA, öğrenme sonucunda yeni verilerin sonucu için de anlamlı çıktılar ve doğruya yakın sonuçlar üretebilmektedir. Bu özelliği ise genelleştirme yeteneği olarak ifade edilmektedir (Ceylan, 2018).

YSA, öğrenme işlevini gerçekleştirirken giriş verilerinden farklı olarak yeni veriler için de uygun ve kabul edilebilir sonuçlar bulabilmektedir.

Ağın eğitiminde kullanılan verilerin bazılarında hatalar olması durumunda; hataların etkilerini veri kümesinin tüm bağlantılarına dağıtması nedeniyle, hata oranını en aza indirerek hatanın kabul edilebilir seviye getirilmesini sağlar. Bu özelliği sayesinde YSA'ların hata toleransı, diğer başka yöntemlere göre de daha fazla olmasını sağlamaktadır. Bu yüzden; YSA'nın eksik, hatalı veriler ve hatta bulunamayan bilgilerle de çalışması mümkündür.

YSA'nın aynı zamanda hızlı bir biçimde bilgileri işleme özelliği bulunmakta ve bu özelliği sayesinde işlem çözümüne yönelik kolaylık da sağlamaktadır.

YSA'nın çalışma prensibi her daim sayısal bilgiler ile olmaktadır, bu yüzden problemlerin sayılarla betimlemek kaçınılmazdır. Bu, YSA'nın bazen çözüme ve kullanım alanına dair dezavantajlar oluşturabilmektedir.

YSA'nın oluşumunda kullanılan değişkenlerin belirlenmesi için belirli ilkeler ve kurallar bulunmadığından; değişkenlerin belirlenmesi kullanıcılara göre farklı olmakta, kullanıcının izlediği yola göre değişkenlik göstermekte ve deneme yanılma ile en uygun çözüm bulunmaktadır. YSA; her değişkene göre bulunduğu sonucu değiştirmekte olduğundan, her uygulanan işlem için farklı inceleme yapılması gerekmektedir.

YSA, problemin çözümü öncesinde herhangi bir belirli olan çıkarımda bulunmayarak, bir matematiksel modele gereksinim duymadan işlemleri yapabilmektedir. YSA yapılarına ve aslında ileri beslemeli bir YSA yapısı olan ve aynı zamanda DÖ'nün bir alt dalı olan KSA yapılarına ilişkin bilinmesi gereken diğer bazı parametreler aşağıda verilmiştir.

Öğrenme Oranı (Learning Rate): MÖ'de öğrenme oranı, en az bir kayıp fonksiyonuna doğru ilerlerken her bir yinelemedeki adım boyutunu belirleyen bir optimizasyon algoritmasında bir ayarlama parametresidir. Diğer bir deyişle, yapay zekâ yöntemlerinde özellikle DÖ metodolojilerinde modelin öğrenme performansını ölçmek için kullanılan önemli bir parametredir.

DÖ'de parametrelerin güncellenmesi geriye yayılım (backpropagation) işlemi ile yapılmaktadır. Geriye yayılım işleminde bu güncelleme işi "chain rule" olarak adlandırılan geriye doğru türev alarak farkın bulunması ve bulunan fark değerinin öğrenme oranı parametresiyle çarpılması, çıkan sonucun ağırlık değerlerinden çıkarılarak yeni ağırlık değerinin hesaplanmasıyla yapılmaktadır. Bu işlem esnasında kullanılan öğrenme oranı parametresi sabit değer olarak belirlenebilir, adım adım artan bir değer olarak da belirlenebilir (örneğin belli bir öğrenme adımına kadar 0,001 o adımdan sonra 0,01 gibi), momentum değerine (öğrenme algoritmasının lokal (yerel) minimuma takılmaması için sıklıkla 0,6-0,8 aralığında değerler alan bir katsayıdır) bağlı olarak

belirlenebilir ya da adaptif algoritmalar tarafından öğrenme esnasında öğrenilebilir. Öğrenme hızı ile ilgili bazı özellikler şunlardır:

- Öğrenme hızını yüksek tutmak veriden çok etkilenmeye sebep vermektedir.
- Öğrenme hızının yüksek olması salınma neden olurken küçük olması da küçük adımlarla ilerleyeceğinden öğrenimin çok uzun sürmesine neden olmaktadır.
- Öğrenme hızı için en uygun çözüm başlangıçta öğrenme hızını yüksek tutmak ve gittikçe azaltmaktır.
- Öğrenme hızının başlangıçta çok küçük olması, lokal optimum değere takılarak global optimum değere hiç ulaşamamasına neden olabilmektedir.
- Öğrenme hızı değeri genelde varsayılan değer olarak 0,01 kullanılmakta belli bir epoch'dan sonra 0,001'e düşürülmektedir (Kurt, 2018).

Kayıp Fonksiyonu (Loss Function): Bir algoritmanın, verileri ne kadar iyi modellediğini değerlendirmenin bir yöntemi kayıp (loss) fonksiyonunu kullanmaktan geçmektedir. DÖ uygulamalarında kullanılan optimizasyon algoritmalarının yardımıyla, kayıp fonksiyonu, tahmindeki hatayı azaltmayı öğrenmektedir. Hata oranı ne kadar yüksek olursa gerçek değer ile tahmin edilen değer arasındaki fark da o kadar yüksek olacaktır. Tasarlanan modeller için ise bu durum model performansının düşüklüğü anlamına gelmektedir (Parmar, 2018).

Genel anlamda kullanılan iki çeşit kayıp fonksiyonu bulunmaktadır. Bu fonksiyonlar: ortalama kare hata ve çapraz entropi olarak adlandırılmaktadır.

Ayrıca, kayıp fonksiyonu ve maliyet fonksiyonu (cost function) birbirinin yerine kullanılsa da aralarında fark vardır. Kayıp fonksiyonu, tek iterasyondaki eğitim örneğini kapsarken; maliyet fonksiyonu, tüm veri setindeki ortalama kayıp oranıdır. YSA'da tasarlanan uygulamaya göre kayıp fonksiyonunun belirlenmesi gerekmektedir. İkili sınıflandırma görevi için "Binary Cross Entropy", çoklu sınıflandırma görevlerinde "Categorical/Multi Cross Entropy" kullanılmaktadır.

Devir (Epoch), İterasyon, Paket Boyutu: Devir (Epoch), tüm veri setinin bir ileri yönde bir de geri yönde tüm ağdan geçmesidir. İterasyon, belirlenen paket boyutu kadarlık verinin ileri ve geri yönde ağdan geçmesidir. Paket boyutu ise ileri ve geri yönde yayılım için veri setinden alınan veri miktarıdır. Paket boyutu yükseldikçe, daha fazla hafıza gerekmektedir. Yüksek paket boyutu seçilmesi her iterasyon için kullanılacak eğitim örneğinin de büyümesi anlamına gelmektedir. 1000 adet veriden oluşan bir veri seti için paket boyutu 500 seçilirse, bir deviri tamamlamak için iki iterasyon gereklidir. Devir sayısının yüksek olması, ağın daha yüksek doğrulukta sonuçlar üreteceği anlamına gelmez. Genelde bu iki parametre, değerlerin her adımda ne kadar değiştiğini ölçmek için kullanılmaktadır (Kurt, 2018).

Erken Durdurma (Early Stopping): Herhangi bir problemin çözümü amacıyla teşkil edilen analiz için belirlenen devir (epoch) sayısı arttıkça aşırı uyum söz konusu olmaktadır. Bu durumu

ortadan kaldırmak amacıyla epoch ile beraber erken durdurma değeri de belirlenmeli ve bu sayede öğrenmenin durduğu noktada analiz sonlandırılmalıdır. Diğer bir deyişle, eğitim verisi ve test verisi hataları arasındaki fark ciddi anlamda artmaya başladığında analizin bitirilmesi işlemidir (Çınar, 2020).

Yığın Normalizasyonu (Batch Normalization): Derin sinir ağlarının eğitimi esnasında katmanlar arası geçişlerdeki girdi değerleri değiştiği için bu durum eğitimi karmaşıklaştırmaktadır. Bu nedenle eğitimin düşük öğrenme oranları ve özenle belirlenmiş parametre değerleri ile başlatılması gerekmektedir. Sorunun çözümü için girdi katmanlarında yapılan normalleştirme işlemini gizli katman girişlerinde de uygulanması önerilmektedir (Ioffe ve Szegedy, 2015). Uygulanan bu işleme yığın normalizasyonu (Batch Normalization) denilmektedir. Yığın normalizasyonunun ağı uygulanması aynı zamanda ağı eğitimi de hızlandırmaktadır. Ayrıca ağı aşırı öğrenme probleminde de çözüm sunarak seyreltme işlemine olan ihtiyacı da azaltmaktadır.

Optimizasyon Fonksiyonları: YSA ve DÖ problemlerinde belirli koşullar altında mümkün olan alternatifler içerisinde en iyisini seçmek için kullanılan fonksiyonlara optimizasyon fonksiyonu adı verilmektedir. Bu bağlamda sıklıkla tercih edilen optimizasyon fonksiyonları şunlardır: AdaGrad, Adam, Stokastik gradyan iniş metodu (SGD), AdaDelta, RMSProp.

Az Öğrenme (Underfit) ve Ezberleme (Overfit) Durumları

Bir YSA veya DÖ 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, söz konusu algoritmalar sadece eğitimi aldığı veri kümesi ile değil aynı zamanda daha önce eğitimi almadığı veri kümesi üzerinde de başarılı bir performans göstermelidir.

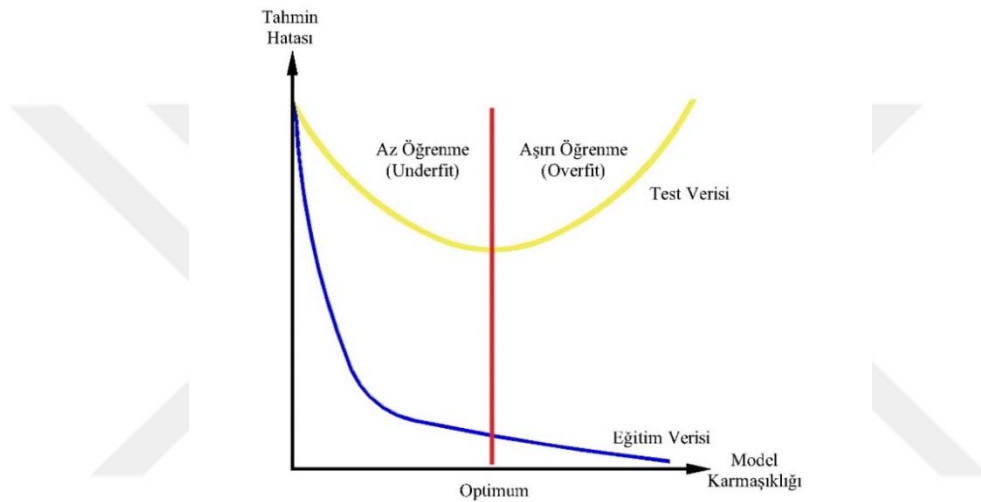
YSA veya DÖ algoritmalarında istenilen bu başarının yakalanamama nedenlerinden birisi yeterli uyumun sağlanamadığı az öğrenme değeri ise aşırı uyum nedeniyle ortaya çıkan ezberleme durumlarıdır.

Bilindiği gibi YSA modelinde ilk olarak eğitim verileri yardımıyla model eğitilir, daha sonra test verileri yardımıyla da eğitilmiş olan model test edilir. Bu aşamalar gerçekleştiikten 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.

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 da 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.

Şekil 4.8’de 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 4.8. Az öğrenme ve aşırı öğrenme durumu

Isı Haritaları (Heatmap/Grad-Cam): YSA’ya girdi olarak verilen görüntülerin sınıflandırılması yapılırken, algoritmanın (mimarinin) görselin tam olarak hangi noktalarına odaklandığı önemli bir detaydır. Mimarilerden elde edilen başarı oranı çok yüksek olsa bile söz konusu ağ eğer görseller üzerinde istenilen noktalara odaklanmamışsa mimari başarısız sayılmaktadır. Bu kararı verebilmek için ısı haritaları denilen yöntem başvurulmaktadır. Örneğin bina cephe görselleri üzerinden bir sınıflandırma yapan algoritmada, ısı haritaları; pencere, çatı, bitki, parapet sınıfları için girdinin hangi bölümlerinin söz konusu kıstaslara benzediğini göstermektedir. Söz konusu haritalar, araştırmacılara ağın neden o görselde bir pencere, çatı, bitki, parapet olduğunu düşündüğünü ve görselin neresinde bahse konu parametrelerin olduğunu göstermektedir. Şekil 4.9’da ısı haritalarına birkaç örnek gösterilmiştir. Isı haritalarındaki renk konfigürasyonu incelendiğinde; kırmızı ve sarı bölgeler (kırmızı bölgelerin sarı bölgelere nispetle daha fazla yoğunlaşmanın olduğu noktalar olduğu unutulmamalıdır), mimarilerin yoğunlukla odaklandığı noktalar olarak yorumlanabilirken mavi bölgeler ise aktivasyonun en az olduğu bölgelerdir.



Şekil 4.9. Pencere, çatı, bitki, parapet arasında sınıflandırma yapan mimariden elde edilen ısı haritaları örneği (Plata ve ark., 2020)

4.1.4. Yapay sinir ağları öğrenme türleri

YSA'da üç farklı öğrenme türü bulunmaktadır. Bunlar; eğitilmiş öğrenme, eğitimsiz öğrenme ve yarı eğitilmiş öğrenmedir (Yetkin, 2014). Ayrıca YSA'da çok çeşitli öğrenme kuralları bulunmaktadır. Bu kurallardan en çok kullanılanları Hebb kuralı, Hopfield kuralı, Kohonen kuralı, delta kuralı, Levenberg-Marquardt (LM) algoritması ve geri yayılım algoritmasıdır.

Eğitilmiş Öğrenme:

Denetimli öğrenme olarak da ifade edilmekte olup mevcut çıktılarla ağ sonucu sağlanan çıktı değerlerinin karşılaştırılması sonucu hata toleransına göre en az düzeye ya da istenilen hata payına gelinceye kadar deneme yanılma işlemini yapar. İstenilen sonuca yaklaşan değerleri elde etmeye başlayan YSA sistemi öğrenmeyi bırakır. YSA'da öğrenme gerçekleştikten sonra girdi değerlerinin ağırlık katsayıları değişmez. Ağı test etmek için ise; test kümesi veya test seti ağa giriş yapılarak eğitimde kullanılmamış çıktı değerleri ile karşılaştırma yapılır. Bu şekilde ağın performansı ve çözümün doğruluğu da ölçülmüş olur. Eğitimin istenilen düzeye gelmesi için gizli katman sayısı

nöron sayısı değiştirilerek yapılan yeni ağların performansı ile mevcut ağdaki performansın durumu karşılaştırılabilir. Bu şekilde en verimli ve en hata payı az olan ağ seçimi gerçekleştirilmiş olur (Yetkin, 2014).

Eğitimsiz Öğrenme:

Denetimsiz öğrenme olarak da ifade edilmekte olup, oluşturulan YSA'ya eğitilmiş öğrenme verilerinden farklı verileri girişi yapılmaz, böylece sadece girdi değerleri ile ağın eğitimi gerçekleştirilmiş olur. Buna göre de ağırlıklar belirlenmiş olur (Yetkin, 2014).

Yarı Eğitilmiş Öğrenme:

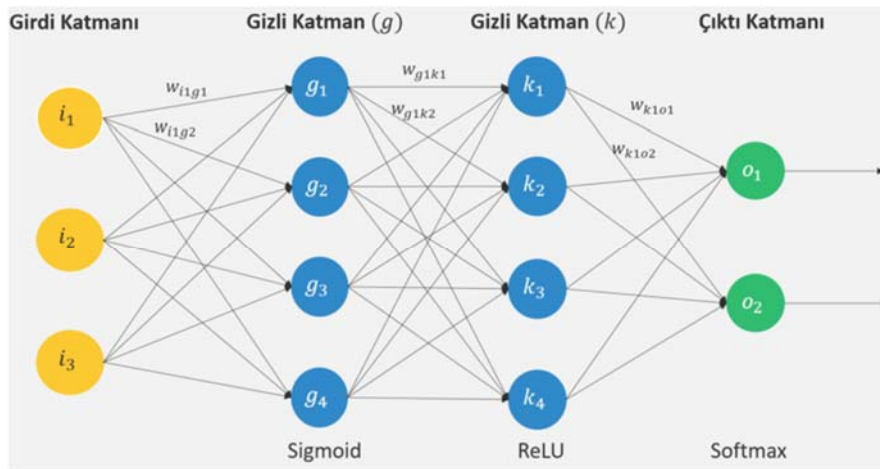
Bu öğrenme türünde YSA'ya giriş değerleri verilir ama ağın eğitimi dışındaki çıktı değerlerine göre bir karşılaştırma ve performansının ölçülmesi işlemi yapılmaz (Yetkin, 2014).

4.1.5. Yapay sinir ağları ağ yapıları

YSA ağ yapısına göre ikiye ayrılmakta olup, bunlar ileri beslemeli YSA ve geri beslemeli YSA'dır. Bunların temel farkı mevcut veriler ileri beslemeli YSA'da sonraki katmana iletilirken, geri beslemeli YSA'da veriler sonraki katmana iletebileceği gibi önceki katmanlara da iletebilmektedir. Diğer taraftan ileri beslemeli YSA'da gecikme olmadığından geri beslemeli YSA'ya göre daha hızlı çözüme ulaşmaktadır.

4.1.6. Yapay sinir ağları katmanları

Tek bir sinir katmanına sahip olan tek katmanlı ve birden çok sinir hücresinin birlikte olması ile ortaya çıkan çok tabakalı ve çok hücreli YSA olan çok katmanlı olmak üzere iki grup bulunmaktadır. Şekil 4.10'da çok katmanlı bir YSA örneği gösterilmektedir.

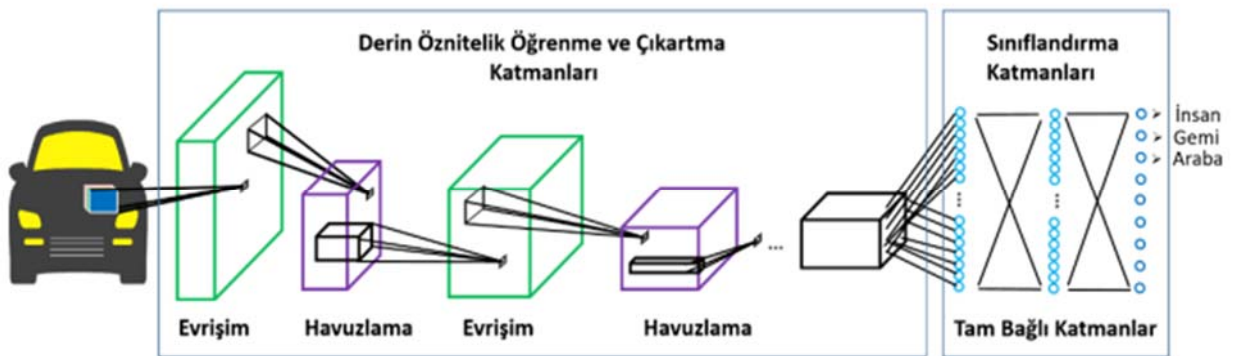


Şekil 4.10. Çok katmanlı YSA örneği (Anonim, 2022)

4.2. Konvolüsyonel (Evrışimli) Sinir Ağları

KSA ileri beslemeli bir YSA örneğidir. KSA yapılarında normal sinir ağı modellerine kıyasla çok az ön işleme kullanılır. KSA'daki ağı modeli, MÖ'deki algoritmaların yanı sıra özellikleri kendisi öğrenir ve yapay sinirler arasındaki ilişkileri kurar. Çok katmanlı yapay sinir ağlarında görüntü sınıflandırılması yapılırken, her piksel ayrı ayrı alınarak bir vektör oluşturur. Bu işlem sonucunda bitişik pikseller arasındaki bilgiler dikkate alınmamış olur. Ayrıca pikseller arasındaki uzamsal ilişki de göz ardı edilmiş olur. Bu durumun üstesinden gelmek amacıyla verilere genellikle ön işleme adımı uygulanır.

KSA'da görüntü içerisinde uzamsal bilgi bir konvolüsyon operatörü ile işleme girer. Konvolüsyon filtreleri, eğitim sırasında değerlerini otomatik olarak öğrenir ve verilerdeki belirli desenleri ortaya çıkarır. KSA yapıları genel olarak konvolüsyon, havuzlama (pooling) ve tam bağlı katmanlardan oluşur. KSA yapılarında konvolüsyon filtreleri kullanılarak belirli desenler çıkarılır. Daha sonrasında havuzlama katmanları ile model içerisindeki gereksiz verilerin görmezden gelinmesi sağlanır. Bu işlemler sonucunda görüntü verilerinde yaygın olarak bulunan belirli desenler elde edilmiş olur. Son adım olarak, elde edilen veriler vektöre dönüştürülür ve sınıflama işlemi yapılır. KSA yapısında ham veriler özellikleri çıkarılarak tek bir vektör olarak temsil edilir. Bu vektörel gösterim görüntünün gri veya renkli olmasına göre değişmektedir. Gri seviyeli görüntülerde tek bir vektör gösterimi bulunurken renkli görüntülerde ise renk kanallarından dolayı üç vektör gösterimi mevcuttur. Konvolüsyonel bir sinir ağının katmanları Şekil 4.11'de verilmiştir (KSA yapılarında veri setlerini bünyesinde barındıran ve çeşitli evrişim ve havuzlama işlemlerinin gerçekleştirildiği safhaya derin öznetelik öğrenme ve çıkartma adı verilmektedir).



Şekil 4.11. Konvolüsyonel sinir ağı yapısının katmanları (Üzen ve ark., 2022)

4.2.1. Giriş katmanı

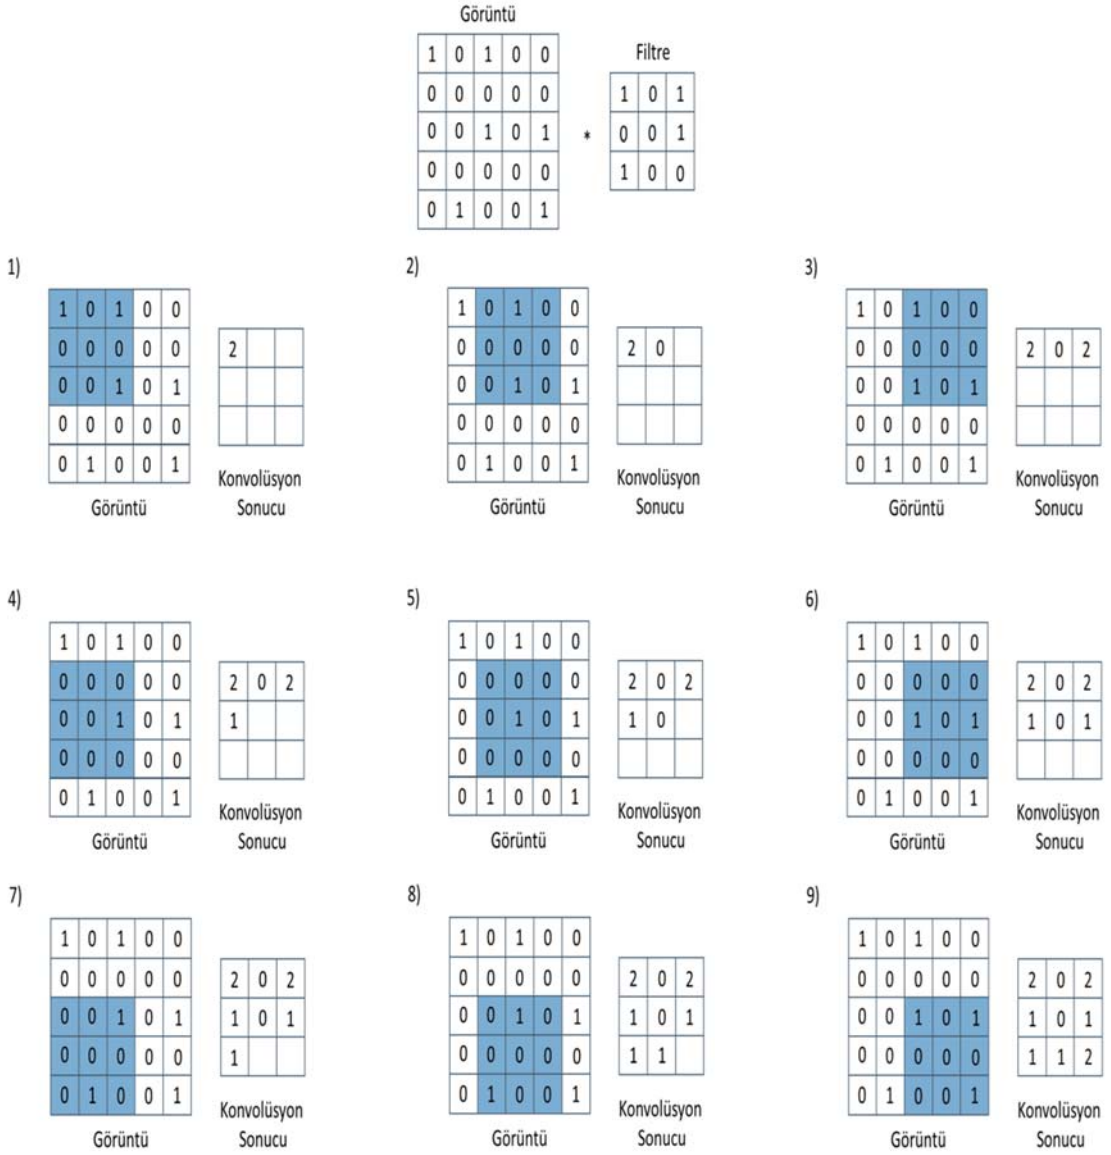
KSA'nın ilk katmanı olan bu katmanda ham veriler ağa aktarılarak ağın eğitimi başlatılmaktadır. Giriş verilerinin boyutu ağın başarımlarını doğrudan etkilemektedir. Veri boyutu

büyüdükçe başarı oranı artabilirken diğer taraftan daha çok bellek ihtiyacı ve daha uzun işlem süresi ihtiyacı da ortaya çıkmaktadır. Bu parametreler göz önünde bulundurularak optimum giriş boyutu tercih edilmelidir.

4.2.2. Konvolüsyon katmanı

Bir konvolüsyon katmanının temel işlevi, girdi verilerinden özellikler elde etmektir. Konvolüsyon, iki fonksiyonun matematiksel bir işleminden oluşur. KSA yapısında konvolüsyon işlemi, eleman bazında çarpım işlemi gerçekleştirilerek ana veriler üzerinde filtre denilen bir çekirdek fonksiyonunun basitçe kaydırılması ile gerçekleştirilir. Kaydırma işlemindeki her pencere için, ilgili elemanların çarpımı o pencerenin sonucunu verir. Tüm görüntü boyunca pencereler kaydırılarak, özellik haritası adı verilen konvolüsyon işleminin çıktısı üretilir.

Şekil 4.12'de, 5x5 boyutunda görüntü matrisi ile 3x3 boyutunda bir konvolüsyon filtresi kullanılarak işlem yapılmıştır. Sol üst köşeden başlayarak, filtre tüm görüntüyü taramaya başlar. Bu sayede görüntünün özellik haritası çıkarılmış olur. Filtre ve giriş görüntüsü arasında bir korelasyon olduğunda, sonuçta ortaya çıkan özellik haritasının bu alanlarda daha yüksek değerlere sahip olduğu görülmektedir. Benzerlik olmadığında ise ortaya çıkan özellik haritasının bu bölgelerde daha düşük değerleri vardır. Bu yüzden filtrelere özellik dedektörleri adı da verilir. Konvolüsyon katmanında, orijinal veriler üzerinde birçok filtre kullanılır. Bu filtrelerin her biri girdi verilerinin farklı desenlerini ve özelliklerini öğrenir. Özellikle kenarları, eğrileri, lekeleri ve pürüzsüz alanları algılamayı öğrenebilirler.



Şekil 4.12. Konvolüsyon işlemi (Özkaya, 2020)

KSA yapılarında konvolüsyon işlemi göz önüne alındığında, düşünülmesi gereken üç tasarım sorunu bulunmaktadır. Bu sorunlar filtre boyutu, filtre sayısı ve kayma adıdır. Bu parametrelerin, çıktı verilerinin oluşumunda ve bellek kullanımı üzerinde etkisi mevcuttur.

Filtre boyutu, konvolüsyon katmanının çıktısını belirleyen bir değişkendir. Filtrenin değerleri modelin ağırlıklarını temsil eder. Örneğin, filtrenin boyutu 3x3 ise, çıktısının giriş katmanındaki 9 farklı düğümle bağlantısı vardır. Girişte tek kanallı gri tonlamalı bir görüntü var ise, filtre de tek kanallı olur. Giriş üç kanallı bir RGB görüntü ise, filtre üç boyutlu bir yapı olarak seçilir. Eğer filtre büyüklüğü çok küçükse, yeterli özellik elde edilmesi mümkün olmaz. Küçük boyuttaki filtreler büyük karmaşık görüntülerden yeterli özellik öğrenemez. Bununla birlikte, küçük boyuttaki filtreler ard arda konvolüsyon işlemi için kullanılırsa, yeterli özellik öğrenilebilir. Filtre boyutunun daha büyük olduğu durumda ise hesaplama karmaşıklığı artmaktadır. Genel olarak, KSA yapısının eğitiminde 3x3 veya 5x5 gibi küçük filtre boyutları kullanılır. Bununla birlikte, son yayınlarda ağdaki boyutu azaltmak

için bazı durumlarda 1x1 boyutunda filtrelerin yararlı olabileceği belirtilmektedir (Szegegy ve ark., 2015).

Konvolüsyon katmanında filtre sayısının belirlenmesi oldukça önemlidir. Çünkü belirlenen filtre sayısına göre öğrenilen özellik sayısı artmaktadır. Filtre sayısı yeterli olmazsa öğrenilmesi gereken bazı özellikler göz ardı edilebilir. Öte yandan, filtre sayısı fazla olması durumunda ise aynı özelliklerin öğrenilme olasılığı vardır. Aynı özellikleri öğrenen filtre sayısının çok olması bellek sorunları meydana getirir.

Her bir filtre giriş görüntüsü üzerinde kaydırıldığında, bir özellik haritası elde edilir. Bu çıktı görüntüleri tüm filtrelerden elde edilen çıktıların birleştirilmesinden oluşur. Giriş görüntüsü iki boyutlu olması durumunda çıktılar üç boyutlu olacaktır. Giriş görüntüsü üç boyutlu hacimsel veri ise, çıktılar dört boyutlu olacaktır. Fazladan boyutların elde edilmesi birçok filtre kullanmaktan kaynaklanır. Görüntünün derinliği ve filtrenin derinliği aynı olmalıdır. 30x30 boyutunda bir giriş görüntüsü ve 3x3 boyutunda bir filtre düşünüldüğünde elde edilen konvolüsyon katman sonucu 28x28 boyutunda olacaktır. Ancak, giriş görüntüsüne uygulanan birden fazla filtre vardır. Bu sebeple çıktı veri boyutu $K \times 28 \times 28$ olur. Bir sonraki konvolüsyon işlemi için filtre boyutu $K \times N \times M$ olur. KSA model temsillerinde, bu boyut genellikle $K @ N \times M$ olarak temsil edilir.

Kaydırma işlemi, filtrenin giriş hacminin etrafında nasıl hareket edeceği hakkında bilgi verir. Genellikle, filtre bir kerede giriş görüntüsünü belirli adım miktarına göre konvolüsyon işleminden geçirir. Bununla birlikte, çıktı matrisinin boyutunu kontrol etmek için adım miktarı değiştirilebilir. Adım miktarı 2 olarak atanırsa filtre 2 birim kayarak işlem yapar.

Konvolüsyon işleminde, çıkış verisinin boyutunu giriş hacmiyle aynı tutmak amacıyla giriş görüntüsüne dolgu eklenebilir. Dolgu boyutu genellikle filtrenin boyutuna göre belirlenir. Filtrenin boyutu 3x3 ise, görüntünün etrafında 1 piksellik dolgu yeterlidir. Filtrenin boyutu 5x5 ise, görüntünün etrafında 2 piksellik dolgu kullanılabilir. Şekil 4.13'te görüldüğü üzere dolgu değerleri genellikle sıfır veya kenar pikselleriyle aynı değer olarak seçilebilir.

	0	0	0	0	0	0	0
	0	0	0	0	0	0	0
	0	0	1	0	0	1	0
	0	0	1	0	1	0	0
	0	0	1	0	1	1	0
	0	0	0	0	0	0	0
	0	0	0	0	0	0	0

Şekil 4.13. Sıfır dolgulu görüntü matrisi (Özkaya, 2020)

Herhangi bir konvolüsyon katmanında çıktı boyutunu hesaplamak için Denk. (4.5) kullanılır.


$$O = \frac{W - K + 2P}{S} + 1 \quad (4.5)$$

(Burada; O: Çıkış katmanının boyutunu belirtirken, W: Giriş katmanının boyutunu gösterir. Aynı zamanda K: Filtre boyutu, P: Dolgu boyutu ve S: Kayma adımıdır.)

4.2.3. RELU (Düzleştirilmiş doğrusal birim) katmanı

Düzleştirilmiş Doğrusal Birim Katmanı evrişim katmanlarından sonra gelmekte ve ağı doğrusal olmayan bir hale sokmak için uygulanmaktadır.

Konvolüsyon katmanında sonra gelen bu katmanda konvolüsyon katmanından gelen verilerdeki negatif değerler sifıra eşitlenmektedir. Bu katmanda aktivasyon fonksiyonları kullanıldığından aktivasyon katmanı olarak da adlandırılmaktadır. Aktivasyon fonksiyonu, ağırlıklı toplam hesaplanarak ve daha sonra bias eklenerek bir nöronun aktive edilip edilmemesine karar verir. Aktivasyon fonksiyonunun amacı, bir nöronun çıkışına nonlineerlik kazandırmaktır. Birçok aktivasyon fonksiyonu olsa da ReLU işlem yapma hızını artırdığı için Ön Eğitimli KSA yapılarında en çok kullanılan fonksiyondur (Şekil 4.14).



Şekil 4.14. RELU aktivasyon fonksiyonu grafiği (Anonim, 2022)


ReLU $[0, +\infty)$ aralığında değer almaktadır. Sigmoid ve Hiperbolik Tanjant aktivasyon fonksiyonları neredeyse tüm nöronların aynı şekilde aktive olmasına sebep olmaktadır. Bu da söz konusu aktivasyon fonksiyonunun çok işlem yapmasına sebebiyet vermektedir. Ağda genel yaklaşım bazı nöronların aktif olup, seyrek aktivasyon işlemi ile verimli bir hesaplama yapılmasının sağlanmasıdır. ReLU aktivasyon fonksiyonu ile bu amaç gerçekleşmiş olur. Şekil 4.14. incelendiğinde fonksiyonun negatif ekseninde 0 değerlerini alması ağın daha hızlı çalışacağı anlamına da gelmektedir. Hesaplama yükünün sigmoid ve hiperbolik tanjant fonksiyonlarına göre az olması

çok katmanlı ağlarda daha çok tercih edilmesine sebep olmuştur. Bu fonksiyonun olumsuz tarafı ise modele işlem hızı kazandıran bu sıfır değer bölgesinin türevinin de sıfır olmasıdır.

4.2.4. Havuzlama (Pooling) katmanı

Alt örnekleme katmanı olarak da adlandırılan havuzlama katmanı, ağdaki parametre sayısını ve hesaplama sayısını azaltarak konvolüsyon katmanı çıktısı olarak elde edilen özellik haritalarından en önemli özellikleri seçer. Bunun yanı sıra havuzlama katmanının aşırı uyum probleminin önüne geçme amacı da vardır. Havuzlama katmanı genellikle iki konvolüsyon katmanı veya konvolüsyon katmanı ile tam bağlı katmanlar arasına yerleştirilir.

Maksimum havuzlama ve ortalama havuzlama, en çok kullanılan havuzlama yöntemlerinden ikisidir. Belirli bir pencere için, maksimum havuzlama bu penceredeki maksimum değeri alır ve ortalama havuzlama penceredeki değerlerin ortalama değerini alır. Havuzlama işleminde, pencere boyutu ve adım değeri olmak üzere iki önemli parametre bulunur. Pencere boyutu, görüntüde taranacak alanın genişliğini belirler. Öte yandan, adım değeri havuzlama penceresinin adım boyutunu belirler. Şekil 4.15'te maksimum ve ortalama havuzlama işlemleri gösterilmiştir.



a)




b)

Şekil 4.15. a) Maksimum havuzlama b) Ortalama havuzlama (Özkaya, 2020)

4.2.5. Tam bağı (Fully connected) katman


Konvolüsyon ve havuzlama katmanı dikdörtgen biçimli çıktılar üretir. Bu çıktılar, vektör formatına dönüştürülerek ağırlık matrisi ile çarpılabilirler. Her biri $5 \times 5 \times 3$ matris boyutunda olan 64 özellik haritası katmanları varsa, tam bağı katman için bu veriler $5 \times 5 \times 3 \times 64 = 4800 \times 1$ vektörüne dönüştürülür. Tam bağı katmandan önceki katman, üst düzey özellikleri temsil eder. Tam bağı bir katman yardımıyla, bu üst düzey özellikler, gizli katmanların ağırlıkları ile çarpılabilir. Sistemin geri kalan kısmı çok katmanlı YSA gibi çalışır (Şekil 4.16).



Şekil 4.16. Konvolüsyonel bir sinir ağında tam bağı katman gösterimi (Er, 2020)

4.2.6. Seyreltme (Dropout) katmanı

Seyreltme katmanı ağı bilgileri ezberlemesini engellemek için kullanılmaktadır. Bunu yapabilmek için de ağdan bazı düğümleri ortadan kaldırmaktadır (Srivastava ve ark, 2014). Şekil 4.17'de ağa seyreltme katmanı uygulanmadan öncesi ve uygulandıktan sonrası gösterilmektedir.



Şekil 4.17. KSA yapısına seyreltme işlemi uygulanması (Ramsundar ve ark., 2020)


Aşırı öğrenme (overfitting), bir modelin eğitim setine özgü istatistiksel düzenleri ezberlemesi, dolayısıyla sonraki yeni veri kümesinde daha kötü performans göstermesi durumudur. Aşırı öğrenmiş bir model daha önce hiç görülmemiş veriler için genelleme yapamadığından bu durum MÖ'deki temel zorluklardan biridir. Aşırı öğrenmeyi engellemek için bu katmanda ağ içinde ezber yapan bazı nöronlar belirlenen oranda rastgele deaktif edilir. Böylelikle ağa genelleme yeteneği kazandırılarak performansı artırılır.

4.2.7. SoftMax aktivasyon fonksiyonu (katmanı)

SoftMax fonksiyonu, çoklu sınıflar için genel lojistik regresyon çeşididir. Regresyon işleminde gerçek sayıların bir giriş vektörü alınır ve N olasılıktan oluşan bir olasılık dağılımı çıkarılır. Hesaplanan tüm olasılık değerleri (0,1) aralığındadır ve bu olasılık değerlerinin toplamı 1'e eşittir (Bishop, 2006). Daha yüksek girdi değerleri daha yüksek olasılık değerlerine neden olur. KSA yapılarında sınıflandırma amacıyla bir SoftMax katmanı kullanılır (Şekil 4.18). Denk 4.6.'da Softmax fonksiyonu tanımlanmıştır.

$$\text{sınıf}_j = \frac{\exp(sf_j)}{\sum_q \exp(sf_q)} \quad (4.6)$$

(Burada; sınıf_j: çıkış değerini, sf_j: softmax aktivasyon fonksiyonu, j: giriş değeridir. sf_q ise, SoftMax katmanındaki her bir yapay siniri gösterir.)



Şekil 4.18. Konvolüsyonel bir sinir ağında softmax aktivasyon fonksiyonu gösterimi (Gülcü ve ark., 2019)

4.2.8. Sınıflandırma katmanı

Son katman olan bu kısma gelmeden önce öznitelikler öğrenen KSA çıkışı, sınıflandırma algoritmalarına girdi olarak kullanılır. Son katmanda sınıflandırılmak istenen nesne sayısı kadar boyuta sahip olan bir vektörü çıkış olarak veren tam bağlı bir katmanların devamıdır. Çıkış sinyali olarak tanıtılmak istenen nesnenin hangi sınıfa ait olduğuna dair olasılıksal değerleri verir. KSA mimarisinin son katmanı, sınıflandırma çıktısını sağlamak için softmax gibi sınıflandırma işlemini sağlayabilecek aktivasyon fonksiyonu olan bir katmanı kullanır.

4.3. Transfer Öğrenme (Ön Eğitimli KSA Yapıları)

Bir problemi çözerken elde edilen bilgiyi saklamak ve daha sonra farklı ama ilgili bir probleme uygulamak üzerine odaklanan MÖ'de kullanılan bir araştırma işlemidir. Diğer bir deyişle bir görev için eğitilmiş bir modelin, ilgili ikinci bir görevde yeniden tasarlandığı MÖ tekniğidir. Konvansiyonel öğrenme işleminde herhangi bir modelin eğitimini gerçekleştirmek fazlaca süre sarfiyatı yaşanmasına sebebiyet vermekte ve aynı zamanda karmaşık ve grift birçok parametrenin uygulanmasını gerektirmektedir. Bu noktada devreye transfer öğrenme yöntemi girmektedir. Transfer öğrenmenin amacı eğitim süresini minimuma indirirken performansı yükseltmektir.

Söz konusu alanda bilhassa yaklaşık 1000 sınıflı görüntü verisinden oluşan ImageNet veri seti sıklıkla kullanılmaktadır. (ImageNet: görsel nesne tanıma yazılım araştırmalarında kullanılmak üzere tasarlanmış büyük bir görsel veri tabanıdır. Söz konusu veri tabanında 14 milyondan fazla görüntü, hangi nesnelerin resmedildiğini göstermek için araştırmacılar tarafından oluşturulmuş ve görüntülerin en az bir milyonda sınırlayıcı kutular da kullanılmıştır.)

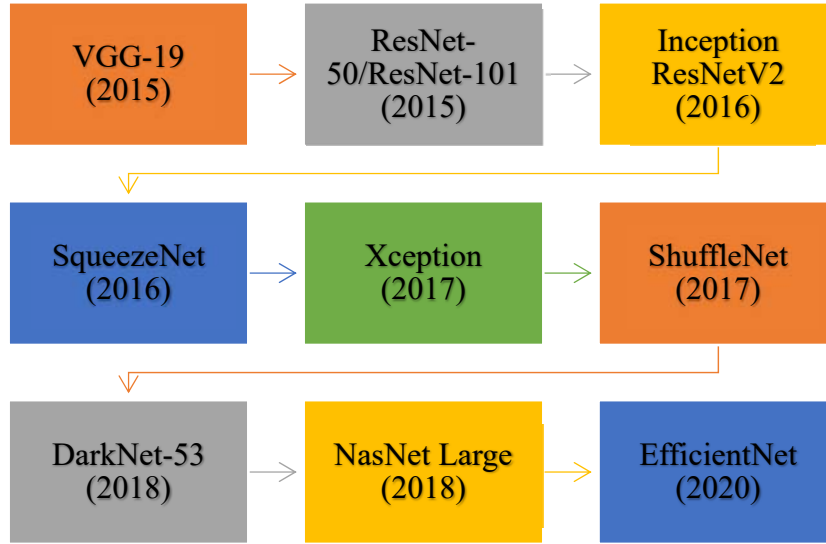
Probleme bağlı olarak araştırmacılar tarafından birçok Ön Eğitimli KSA mimarisi kullanılmaktadır.

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 düzenlemelerden herhangi birinin uygulanması gerekmektedir (Ashames, 2020).

Bu tez çalışmasında söz konusu transfer öğrenme mimarilerinden olan DarkNet-53, EfficientNet, Inception ResNetV2, Nasnet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50 modelleri kullanılmıştır. Bu ağ yapıları birbirinden oldukça farklı olduğu gibi benzerlikleri de bünyesinde barındırmakla birlikte her biri farklı problemlerin çözümü için tasarlanmıştır. Şekil 4.19'da Ön Eğitimli KSA mimarilerinin kronolojisi verilmiştir.



Şekil 4.19. Ön Eğitimli KSA mimarileri kronolojisi

4.3.1. VGG-19

Visual Geometry Group-19 (VGG-19) Simonyan ve Zisserman (2015) tarafından geliştirilen 16 evrişim, 3 tam bağlı, 5 maksimum havuzlama ve 1 entropi (softmax) olmak üzere toplam 19 katman içeren bir DÖ ağıdır (Simonyan ve Zisserman, 2014). Çizelge 4.2’de VGG-19 mimarisinin genel yapısı verilmiştir.

Çizelge 4.2. VGG-19 mimarisi

Katman (Layer) İsmi	Çıkış Boyutu	19 Katman (Layer)
Conv. 1	224×224	3×3, 64, Stride 2 2×2 max. Pool, Stride 2
Stage 1: Conv2_x	112×112	$\begin{pmatrix} 3 \times 3 \ 64 \\ 3 \times 3 \ 64 \end{pmatrix}$
Stage 2: Conv3_x	56×56	$\begin{pmatrix} 3 \times 3 \ 128 \\ 3 \times 3 \ 128 \end{pmatrix}$
Stage 3: Conv4_x	28×28	$\begin{pmatrix} 3 \times 3 \ 256 \\ 3 \times 3 \ 256 \\ 3 \times 3 \ 256 \\ 3 \times 3 \ 256 \end{pmatrix}$
Stage 4: Conv5_x	14×14	$\begin{pmatrix} 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \end{pmatrix}$
Stage 5: Conv6_x	7×7	$\begin{pmatrix} 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \\ 3 \times 3 \ 512 \end{pmatrix}$
Binary-Multi Classification Stage	1×1	Average Pool, 1000-d FC, Softmax

4.3.2. ResNet50-ResNet101

Bu CNN mimarisinde derin bir artık (residual) öğrenme çerçevesi sunularak bozulma sorunu ele alınmaktadır. Her birkaç yığın katmanın doğrudan istenen temel haritalamaya uymasını beklemek yerine bu katmanların artık bir haritalamaya uymasına izin verilen bir sistematik oluşturulmuştur. Biçimsel olarak, istenen temel eşlemeyi $H(x)$ olarak ifade ederek, yığılmış doğrusal olmayan katmanların başka bir $F(x) = H(x) - x$ eşlemesine uymasına izin verilmiştir. Orijinal eşleme $F(x) + x$ olarak yeniden düzenlenmiştir. Artık eşlemeyi optimize etmenin orijinal, referanssız eşlemeyi optimize etmekten daha kolay olduğu varsayılmak suretiyle söz konusu mimari teşkil edilmiştir (He ve ark., 2015).

ResNet (Residual Network) mimarisi, DÖ ağlarında çok katmanlı bir ağ aracılığıyla önceki katmanların değerini sonraki katmanlara aktararak iyi sonuçların korunmasına yardımcı olmaktadır. Söz konusu ağda konvolüsyon katmanlarının girişi ile çıkışı arasında bir kısayol (shortcut) bağlantısı yapılmıştır. Bu bağlantı sayesinde konvolüsyon katmanlarının çıkışına iki önceki katmandan gelen

değerler eklenmiş olmaktadır. Mevcut ağırlık 0 olsa bile önceki katmandan gelen değerler ile öğrenme hatası optimize edilmiş olur.

Bu mimari esas olarak VGG ağlarının felsefesinden esinlenmiştir. ResNet-50 ve ResNet-101 CNN mimarileri, Çizelge 4.3 ve Çizelge 4.4'te gösterilmektedir.

Çizelge 4.3. ResNet-50 mimarisi

Katman (Layer) İsmi	Çıkış Boyutu	50 Katman (Layer)
Conv. 1	112×112	7×7, 64, Stride 2 3×3 max. Pool, Stride 2
Stage 1: Conv2_x	56×56	$\begin{pmatrix} 1 \times 1 \ 64 \\ 3 \times 3 \ 64 \\ 1 \times 1 \ 256 \end{pmatrix} \times 3$
Stage 2: Conv3_x	28×28	$\begin{pmatrix} 1 \times 1 \ 128 \\ 3 \times 3 \ 128 \\ 1 \times 1 \ 512 \end{pmatrix} \times 4$
Stage 3: Conv4_x	14×14	$\begin{pmatrix} 1 \times 1 \ 256 \\ 3 \times 3 \ 256 \\ 1 \times 1 \ 1024 \end{pmatrix} \times 6$
Stage 4: Conv5_x	7×7	$\begin{pmatrix} 1 \times 1 \ 512 \\ 3 \times 3 \ 512 \\ 1 \times 1 \ 2048 \end{pmatrix} \times 3$
Binary-Multi Classification Stage	1×1	Average Pool, 1000-d FC, Softmax

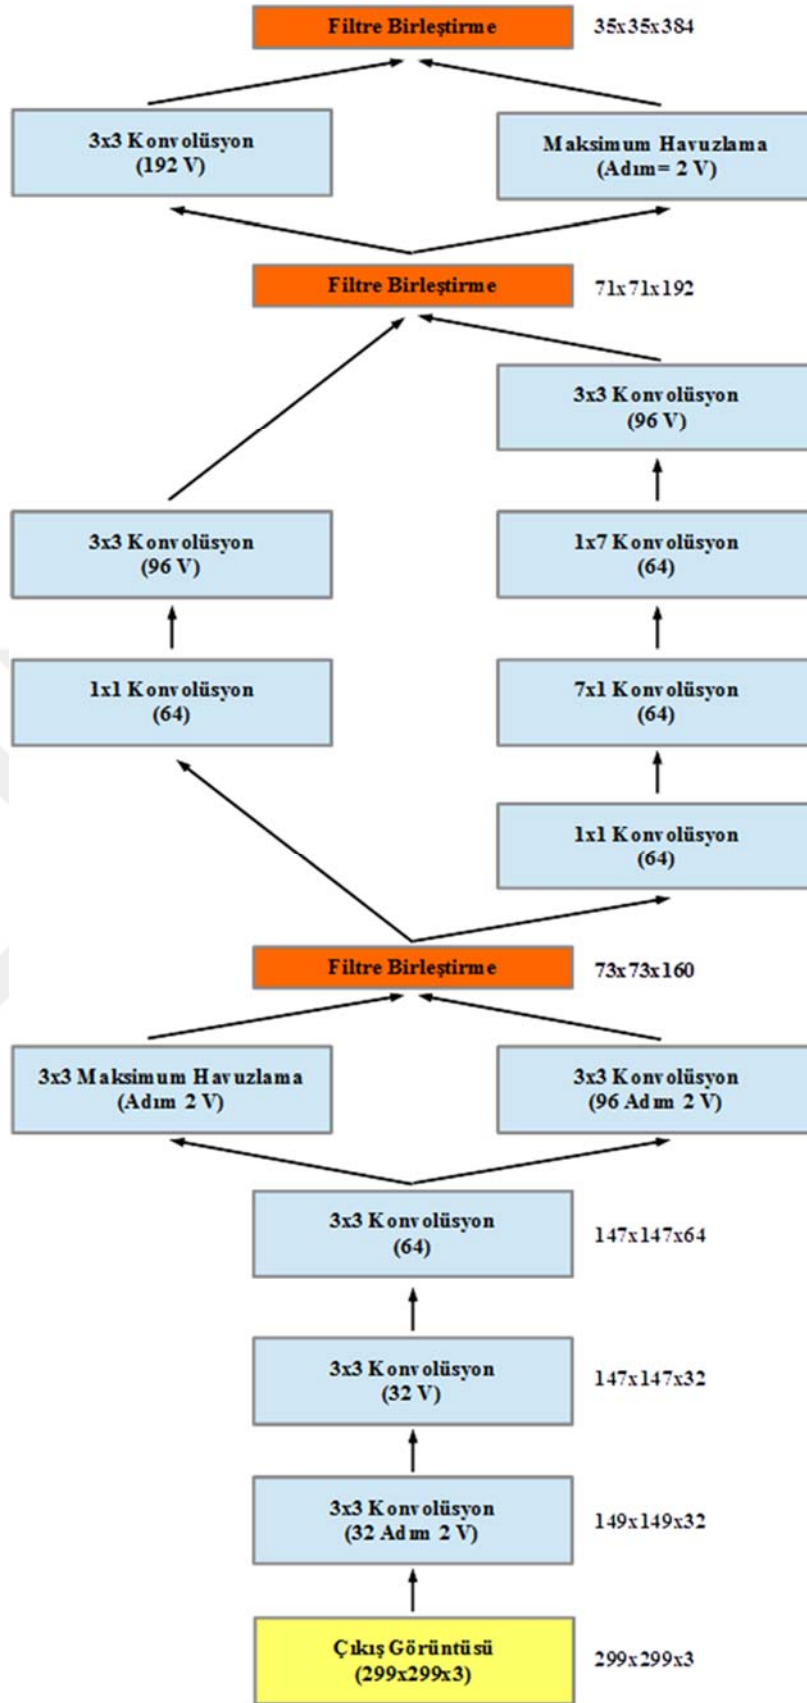
Çizelge 4.4. ResNet-101 mimarisi

Katman (Layer) İsmi	Çıkış Boyutu	101 Katman (Layer)
Conv. 1	112×112	7×7, 64, Stride 2 3×3 max. Pool, Stride 2
Stage 1: Conv2_x	56×56	$\begin{pmatrix} 1 \times 1 \ 64 \\ 3 \times 3 \ 64 \\ 1 \times 1 \ 256 \end{pmatrix} \times 3$
Stage 2: Conv3_x	28×28	$\begin{pmatrix} 1 \times 1 \ 128 \\ 3 \times 3 \ 128 \\ 1 \times 1 \ 512 \end{pmatrix} \times 4$
Stage 3: Conv4_x	14×14	$\begin{pmatrix} 1 \times 1 \ 256 \\ 3 \times 3 \ 256 \\ 1 \times 1 \ 1024 \end{pmatrix} \times 23$
Stage 4: Conv5_x	7×7	$\begin{pmatrix} 1 \times 1 \ 512 \\ 3 \times 3 \ 512 \\ 1 \times 1 \ 2048 \end{pmatrix} \times 3$
Binary-Multi Classification Stage	1×1	Average Pool, 1000-d FC, Softmax

4.3.3. Inception ResNetV2

Faster R-CNN (maliyet açısından yük olan seçici arama (selective search) işleminin yerine daha kullanışlı olan bölgesel öneri ağlarını (region proposal network) dikkate alan CNN modelidir.) mimarisi kapsamında geliştirilmiş olan mimaridir. Artık bağlantılar (residual connections) ve başlangıç (Inception) mimarilerinin birlikte kullanımı ile oluşturulmuştur. Inception-ResNet V2’de kullanılan mimariler Inception mimarilerinde birbirine bağlanma aşamasında kullanılan filtreler yerine ResNet mimarisi kullanılarak iki ağ iç içe geçirilmiştir. Bu mimari birleşim artık bağlantılar içerisinde kullanılan artık yaklaşımının avantajlarından yararlanılmasına ve hesaplama verimliliğinin korunmasına imkân vermiştir (Szegedy ve ark., 2016).

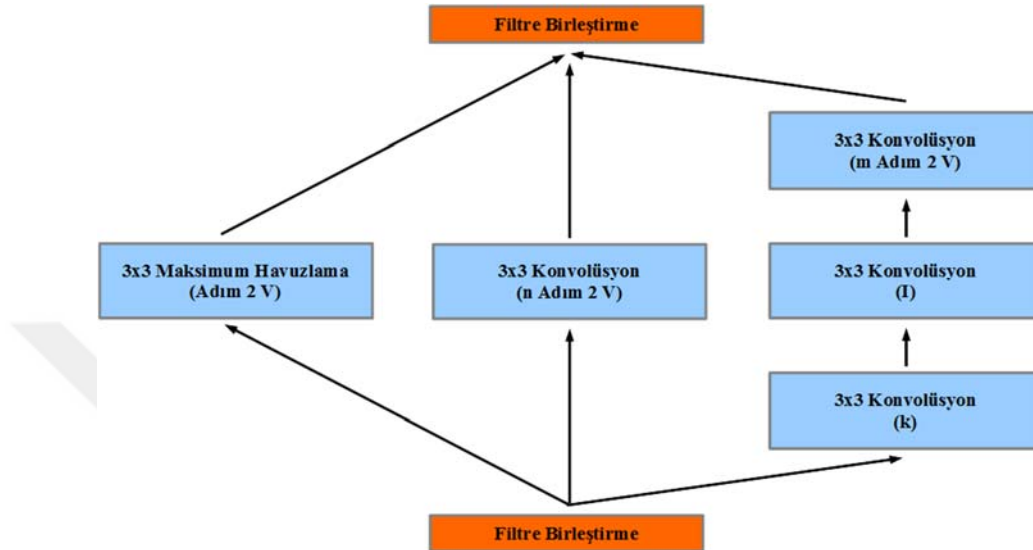
Inception ve ResNet mimarilerinin birlikte kullanıldığı ağda kullanılan inception mimarisi 4 farklı versiyon olarak tasarlanmıştır. Bu tez kapsamında Inception ResNetV2 mimarisi kullanılmıştır. Inception mimarisi kullanılan pür inception blokları bellekteki modeli sığdırabilmek için bölümlenerek eğitilmiştir. Inception mimarisi parametrelerinin çoğu değiştirilebilir formatta dizayn edilmiştir. Inception mimarisinin verimini etkilemeden çeşitli katmanlarda farklı filtre sayıları kullanılabilir. Eğitim hızını optimize etmek için ve çeşitli alt ağlar arasındaki hesaplamayı dengelemek için katman boyutları dikkatlice ayarlanarak kullanılmıştır. Tensorflow kütüphanesindeki versiyonlarda kullanılan kopya versiyonlar bölümlenmeden eğitilebilmektedir. Geri yayılım tarafından kullanılan belleğin son optimizasyonlarının bir kısmı gradyan hesaplaması ve bilgisayarın yapılandırılması için gerekli tensörlerin azaltılması ile elde edilmiştir. (Szegedy ve ark., 2016). Inception ağlarının ResNet (artık bağlantı) kullanan sürümleri için daha basit inception blokları kullanılmıştır. Her bir inception bloğunun ardından 1x1 aktivasyon kullanılmayan konvolüsyon sinir ağı gelmektedir. Bu, filtre bloğunun boyutunun girişin derinliğine uyması için kullanılan ek katmandır. Inception bloğunun neden olduğu boyutsal azaltmayı minimize etmek için kullanılır.



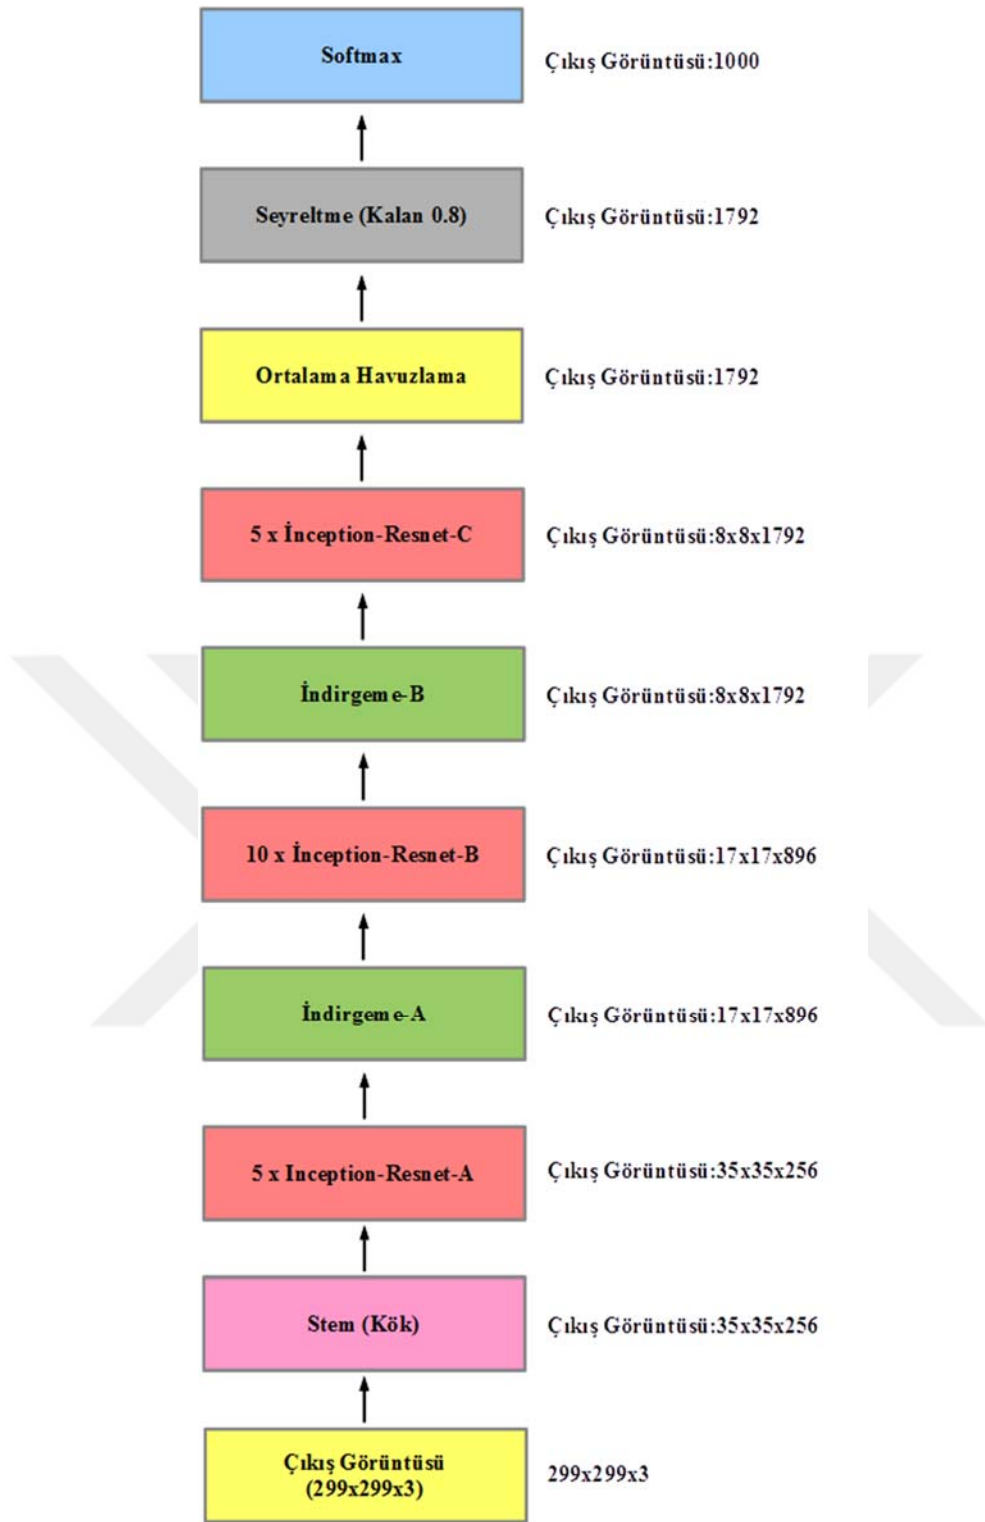
Şekil 4.20. Inception ResNetV2 ağının ana (kök) şeması (Szegedy ve ark., 2016)

Inception ResNet ve normal inception versiyonları arasındaki farklardan bir tanesi toplu normalizasyonu (batch normalization) genel olarak katmanların üstünde kullanmak yerine sadece geleneksel katmanların üstünde kullanmaktır. Toplu normalizasyonda (batch normalization) yapılan

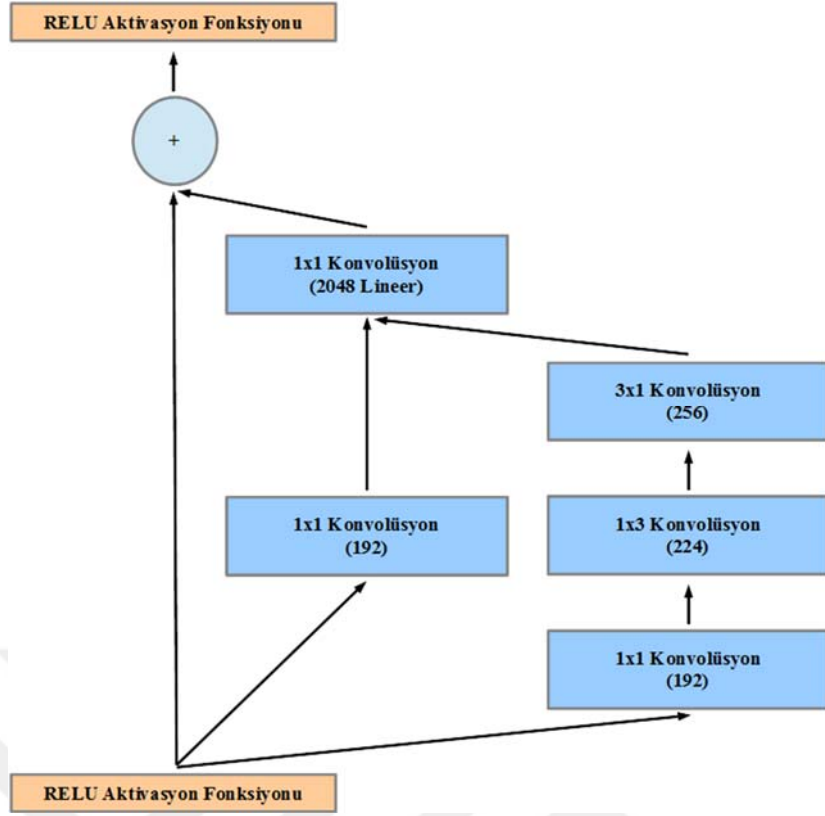
işlemler tek bir grafik işlemcide saklanarak kullanılmıştır. Genel olarak katmanlar büyük işlemlerle birlikte hafıza izi grafik işlemci hafızasında fazlaca yer tutmaktadır. Bu genel katmanlardaki toplu normalizasyonu (batch normalization) atlamak suretiyle Inception blokları sayısı büyük ölçüde artırılmıştır. Inception ResNetV2 mimarisinin algoritma şeması Şekil 4.20, Şekil 4.21, Şekil 4.22, Şekil 4.23, Şekil 4.24. ve Şekil 4.25'te gösterilmiştir.



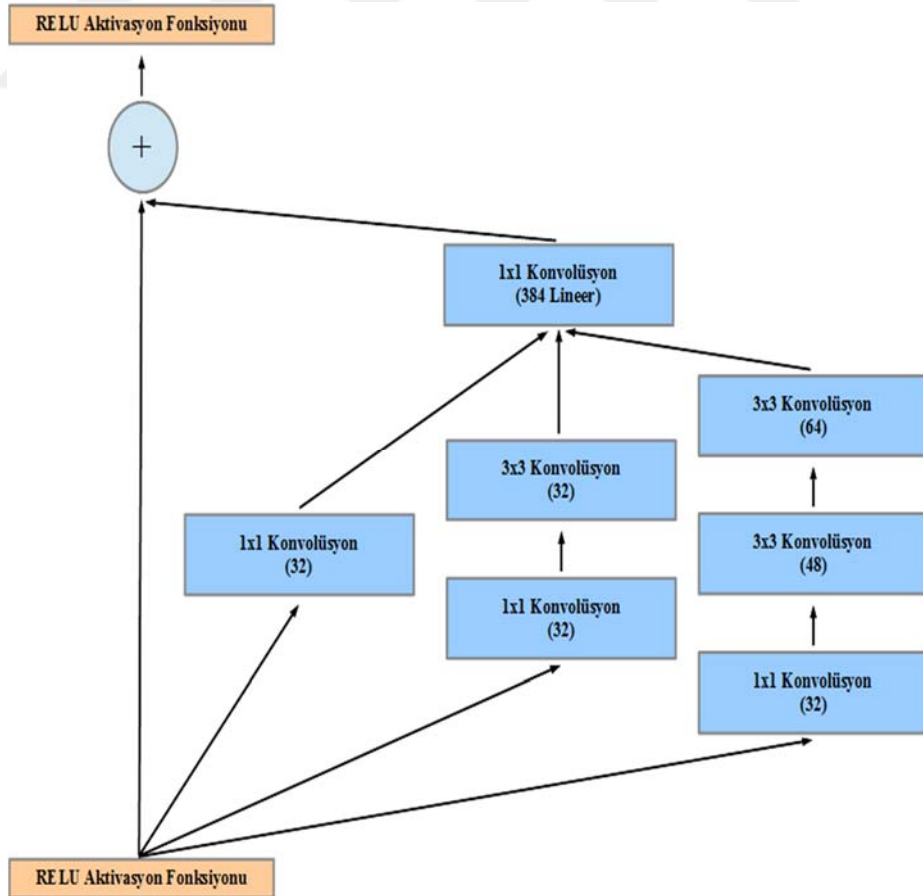
Şekil 4.21. Inception ResNetV2 35 x 35, 17 x 17 indirgeme şeması (Szegedy ve ark., 2016)



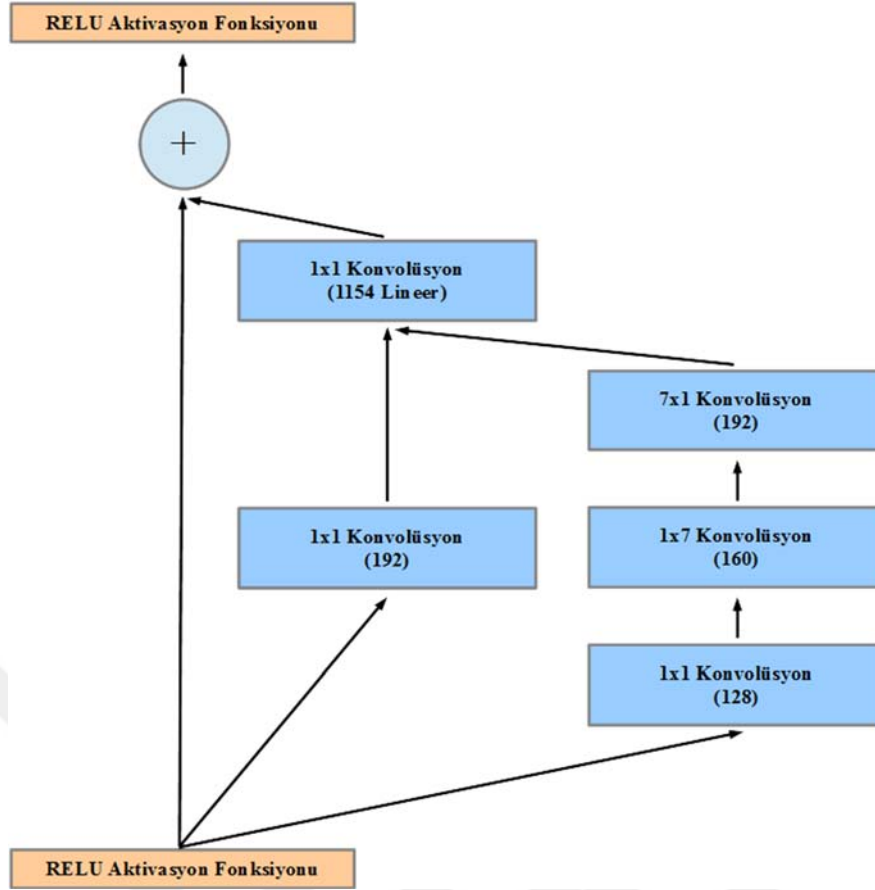
Şekil 4.22. Inception ResNetV2’de kullanılan katmanların şematize gösterimi (Szegedy ve ark., 2016)



Şekil 4.23. Inception ResNetV2 35 x 35 grid modeli (Inception ResNet A) ve 17 x17 grid modeli (Inception ResNet B) (Szegedy ve ark., 2016)



Şekil 4.24. Inception ResNetV2 8 x8 grid modeli (Inception ResNet C) (Szegedy ve ark., 2016)



Şekil 4.25. Inception ResNetV2 8 x8 grid modeli (Inception ResNet C) (Szegedy ve ark., 2016)

Tez kapsamında Inception-Resnet V2 mimarisinin yapıları gösterilmiştir. Bu algoritma görüntüleri içerisinde V harfi ile gösterilmeyen konvolüsyon sinir ağlarında giriş ızgara (grid) sayısı çıkış ızgara sayısına eşittir. V harfi ile gösterilen konvolüsyon sinir ağlarında V değeri kadar doldurulmalı ve bir önceki katmana göre azaltılarak giriş ızgara sayısı orantılı olarak azaltılmalı ve çıkış ızgara sayısı ayarlanmalıdır.

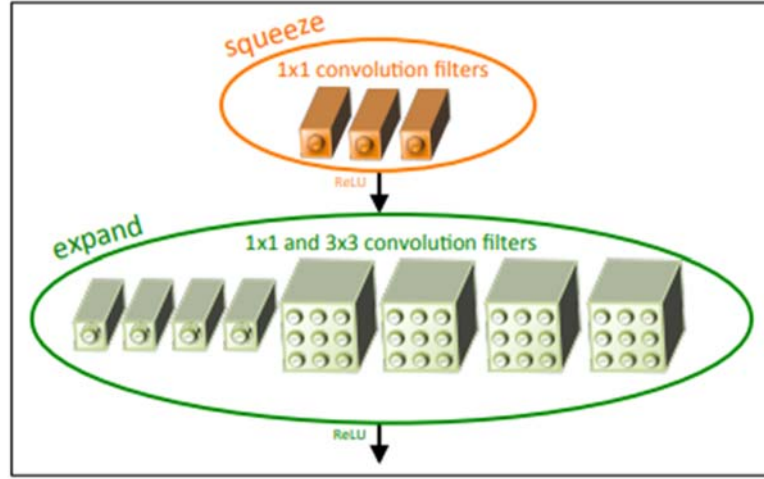
4.3.4. SqueezeNet

SqueezeNet, N. Forrest ve ark. (2016) tarafından geliştirilen bir KSA yapısıdır. Daha küçük konvolüsyon filtreleri ile toplamda güncellenmesi gereken parametreyi azaltmak için kullanılabilecek az sayıda kanal kullanımı ile SqueezeNet KSA yapısı tasarlanmıştır. SqueezeNet yapısı bağımsız bir konvolüsyon yapısı ile başlamış ve daha sonra 8 fire modülü kullanılmıştır. Bu modüller bir çeşit uyum yapısıdır. Fire modüllerinde, tasarlanan ağın son katmanlarına doğru filtre sayısı artırılmıştır. Bu işlemden sonra, ağ bir konvolüsyon katmanı ile sonlandırılmıştır. Bu katmanın ardından, maksimum havuzlama ile özellik çıkarımı sağlanmaktadır. Ayrıca aktivasyon ve kaçınma katmanları, aşırı uyum problemini önlemek için kullanılmıştır (Verma ve ark., 2017).

SqueezeNet Mimari Tasarım Stratejileri:

- **Strateji 1:** 3x3 filtreler 1x1 filtrelerle değiştirilmiştir. Belirli sayıda evrişim filtresi kullanmak gerektiğinde, 1x1 filtrenin 3x3 filtreden 9 kat daha az parametresi olduğundan, bu filtrelerin çoğu 1x1 yapılmıştır (Forest ve ark., 2016).
- **Strateji 2:** Giriş kanallarının sayısı 3x3 filtrelere azaltılmıştır. Tamamen 3x3 filtrelerden oluşan bir evrişim katmanı düşünüldüğünde, bu katmandaki toplam parametre miktarı (giriş kanalı sayısı) x (filtre sayısı) x (3 x 3)'tür. Bu nedenle, bir CNN'de az sayıda toplam parametreyi korumak için, yalnızca 3x3 filtrelerin sayısını azaltmak (yukarıdaki Strateji 1'e bakın) değil, aynı zamanda 3x3 filtrelere giden giriş kanallarının sayısını azaltmak da önemlidir. Dolayısıyla ile giriş kanallarının sayısı 3x3 filtrelere indirilmiştir (Forest ve ark., 2016).
- **Strateji 3:** Evrişim katmanlarının büyük aktivasyon haritalarına sahip olması için ağda geç örnekleme yapılmıştır. Evrişimli bir ağda, her evrişim katmanı, en az 1x1 ve genellikle 1x1'den çok daha büyük bir uzamsal çözünürlüğe sahip bir çıktı etkinleştirme haritası üretilmektedir. Bu aktivasyon haritalarının yüksekliği ve genişliği şunlar tarafından kontrol edilir: (1) giriş verilerinin boyutu (örneğin 256x256 görüntüler) ve (2) CNN mimarisinde alt örnekleme yapılacak katmanların seçimi. Yaygın olarak; alt örnekleme, bazı evrişim veya havuzlama katmanlarında (adım > 1) ayarlanarak CNN mimarilerinde kullanılmaktadır. Ağdaki ilk katmanların büyük adımları varsa, çoğu katmanın küçük aktivasyon haritaları olacaktır. Tersine, ağdaki katmanların çoğu 1 adıma sahipse ve 1'den büyük adımlar ağın sonuna doğru yoğunlaşmışsa, ağdaki birçok katman büyük aktivasyon haritalarına sahip olacaktır. Büyük aktivasyon haritaları diğer her şey eşit tutularak daha yüksek sınıflandırma doğruluğuna yol açabilecektir. Bu strateji, sınırlı bir parametre kullanılarak doğruluğu en üst düzeye çıkarmakla ilgilidir. (Forest ve ark., 2016).

Fire Modülü: Bir Fire modülü şunlardan oluşmaktadır: 1x1 ve 3x3 evrişim filtrelerinin bir karışımına sahip bir genişletme katmanına beslenen bir sıkıştırılmış evrişim katmanıdır (yalnızca 1x1 filtrelere sahiptir). Şekil 4.26'da bu katman gösterilmektedir. Fire modüllerinde 1x1 filtrelerin serbest kullanımı, Strateji 1'in bir uygulamasıdır. Bir Fire modülünde üç ayarlanabilir boyut (hiperparametreler) ortaya koyulmuştur: s_{1x1} , e_{1x1} ve e_{3x3} . Bir Fire modülünde, s_{1x1} , sıkıştırma katmanındaki filtrelerin sayısıdır (tümü 1x1), e_{1x1} , genişletme katmanındaki 1x1 filtrelerin sayısıdır ve e_{3x3} , genişletme katmanındaki 3x3 filtrelerin sayısıdır. Fire modülleri, s_{1x1} 'i, $(e_{1x1} + e_{3x3})$ 'ten küçük olacak şekilde ayarlanmıştır. Bu nedenle, Strateji 2'ye göre, sıkıştırma katmanı 3x3 filtrelere giriş kanallarının sayısını sınırlamaya yardımcı olmaktadır. (Forest ve ark., 2016).



Şekil 4.26. Fire modülünde evrişim filtrelerinin gösterimi (Szegedy ve ark., 2016)

Çizelge 4.5'te SqueezeNet'in bağımsız bir evrişim katmanıyla (conv.1) başladığı, ardından 8 fire modülünün (fire2-9) son bir dönüşüm katmanıyla (conv.10) sona erdiği görülmektedir. Ağın başından sonuna kadar fire modülü başına filtre sayısı kademeli olarak artırılmaktadır. SqueezeNet; conv.1, fire4, fire8 ve conv.10 katmanlarından sonra ikişerli bir adımla maksimum havuzlama gerçekleştirir; bu nispeten geç havuzlama yerleşimleri, Strateji 3'e göre yapılmaktadır. (Forest ve ark., 2016).

Çizelge 4.5. SqueezeNet mimarisi

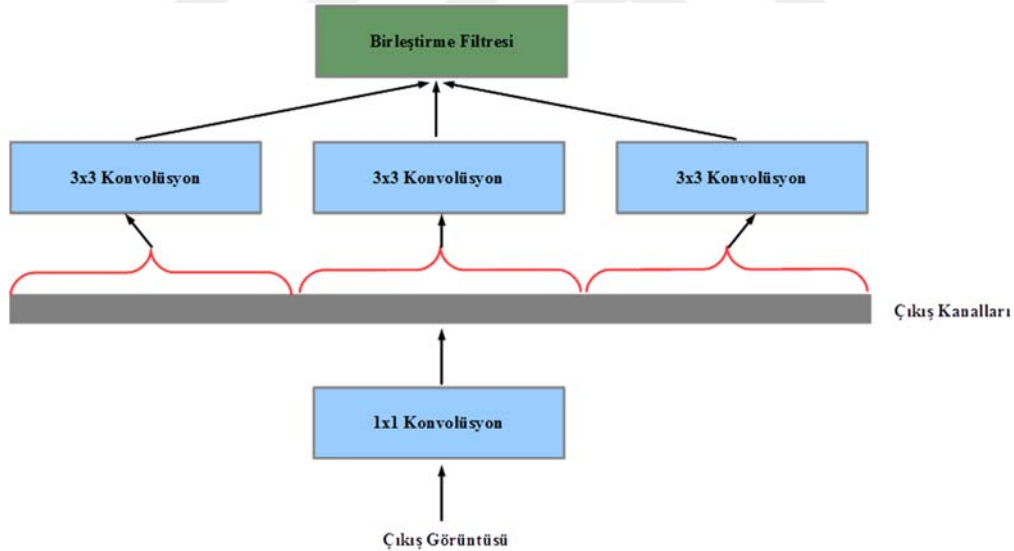
Layer (Tür)	Çıktı Boyutu	Filtre Boyutu/Stride	Derinlik	s ₁ x ₁	e ₁ x ₁	e ₃ x ₃
Giriş görüntüsü	224 x224 x3					
conv_1	111 x111 x96	7 x7/2(x96)	1			
maxpool1	55 x55 x96	3 x3/2	0			
fire2	55 x55 x128		2	16	64	64
fire3	55 x55 x128		2	16	64	64
fire4	55 x55 x256		2	32	128	128
maxpool4	27 x27 x256	3 x3/2	0			
fire5	27 x27 x256		2	32	128	128
fire6	27 x27 x384		2	48	192	192
fire7	27 x27 x384		2	48	192	192
fire8	27 x27 x512		2	64	256	256
maxpool8	13 x12 x512	3 x3/2	0			
fire9	13 x12 x512		2	64	256	256
conv_10	13 x12 x1000	1 x1/1(x1000)	1			
avgpool10	1 x1 x1000	13 x13/1	0			

4.3.5. Xception

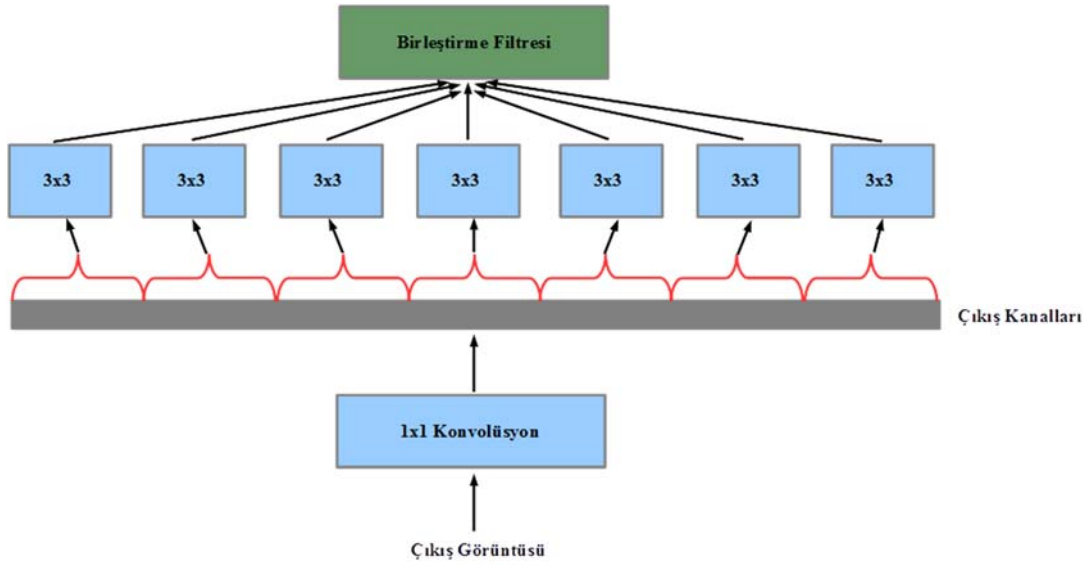
Xception, Derinlemesine Ayrılabilir Evrişimleri içeren derin bir evrişimsel sinir ağı mimarisidir. Google araştırmacıları tarafından (2017) geliştirilmiştir. Google, CNN'lerde Başlangıç modüllerinin bir yorumunu, normal evrişim ile derinlemesine ayrılabilir evrişim işlemi (derinlik yönünde bir evrişim ve ardından noktasal bir evrişim) arasında bir ara adım olarak sunmuştur.

Evrişimler ve ayrılabilir evrişimler arasındaki süreklilik:

Bu mimari yapı daha güçlü hipoteze dayanan bir Inception modülünün "aşırı" bir versiyonu olup önce kanallar arası korelasyonları eşleştirmek için 1x1'lik bir evrişim kullanmış ve ardından her çıkış kanalının uzamsal korelasyonlarını ayrı ayrı haritalamıştır. Diğer bir ifade ile Xception, derinlemesine ayrılabilir evrişim katmanlarına dayanan bir CNN'dir. Aslında, ortaya atılan hipotez şudur: KSA'ların özellik haritalarındaki kanallar arası korelasyonların ve uzamsal korelasyonların haritalanmasının tamamen ayrıştırılabileceğidir. Bu hipotez, Inception mimarisinin altında yatan hipotezin daha güçlü bir versiyonu olduğu için de önerilen mimariye "Extreme Inception" anlamına gelen Xception adı verilmiştir (Chollet, 2017). Şekil 4.27'de Basitleştirilmiş Inception modülü formülasyonu verilmiş iken Şekil 4.28'de ise Xception modülü gösterilmiştir.



Şekil 4.27. Basitleştirilmiş Inception modülü formülasyonu (Chollet, 2017)



Şekil 4.28. Inception modülünün aşırı bir formülasyonu (Chollet, 2017)

Derinlemesine ayrılabilir evrişim, TensorFlow ve Keras gibi DÖ çerçevelerinde yaygın olarak "ayrılabilir evrişim" olarak adlandırılır, derinlemesine bir evrişimden oluşur, yani bir girdinin her kanalı üzerinde bağımsız olarak gerçekleştirilen bir uzaysal evrişim, ardından noktasal bir evrişim, yani 1x1 evrişim, derinlik yönünde evrişim tarafından çıkan kanalların yeni bir kanal uzayına yansıtılması işlemidir. Bu, görüntü işleme alanında yaygın olarak "ayrılabilir evrişim" olarak da adlandırılmaktadır ancak uzaysal olarak ayrılabilir bir evrişim ile karıştırılmaması gerekmektedir (Chollet, 2017).

Bir Başlangıç modülünün "aşırı" versiyonu ile derinlemesine ayrılabilir bir evrişim arasındaki iki fark aşağıda verilmiştir:

- İşlemlerin sırası: genellikle uygulandığı gibi (örneğin TensorFlow'da) derinlemesine ayrılabilir evrişimlerde önce kanal bazında uzaysal evrişim gerçekleştirilir ve ardından 1x1 evrişim gerçekleştirilir, Inception'da ise önce 1x1 evrişim gerçekleştirilir (Chollet, 2017).
- İlk işlemten sonra doğrusal olmayan bir durumun varlığı veya yokluğu: Inception'da, her iki işlemi bir ReLU doğrusal olmama durumu izler, ancak derinlemesine ayrılabilir evrişimler genellikle bu durum doğrusallık olmadan uygulanır (Chollet, 2017).

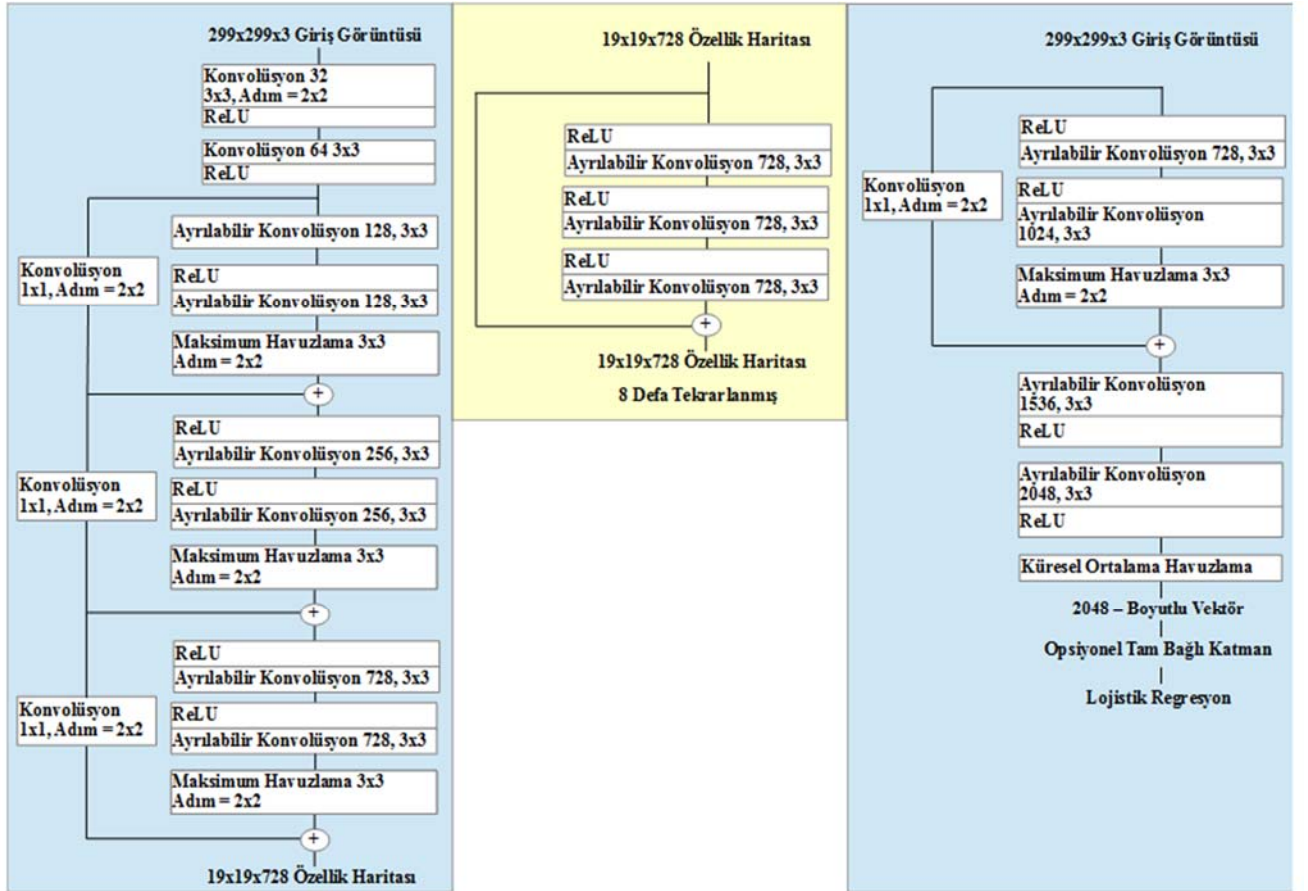
Özellikle bu işlemlerin yığılmış bir ortamda kullanılması amaçlandığından, ilk farkın önemsiz olduğunu savunulmaktadır.

Ayrıca, normal Inception modülleri ve derinlemesine ayrılabilir evrişimler arasında yer alan Inception modüllerinin diğer ara formülasyonlarının da mümkün olduğu ifade edilmiştir. Aslında, düzenli evrişimler ve derinlemesine ayrılabilir evrişimler arasında, bağımsız kanal uzay bölümlerinin sayısı ile parametrelenen uzaysal kısımları gerçekleştirmek için kullanılan ayrı bir spektrum vardır. Bu spektrumun bir ucundaki düzenli bir evrişim (1x1 evrişimden önce gelir) tek parçalı duruma karşılık gelir; derinlemesine ayrılabilir bir evrişim ise kanal başına bir segmentin olduğu diğer uca

karşılık gelir. Inception modülleri, birkaç yüz kanalı 3 veya 4 parçaya bölerek aralarında yer alır. Bu tür ara modüllerin özellikleri henüz keşfedilmemiştir (Chollet, 2017).

Bu çıkarımlar yapıldıktan sonra, Inception modüllerini derinlemesine ayrılabilir evrişimlerle değiştirerek, yani derinlemesine ayrılabilir evrişim yığınları olacak modeller oluşturularak, Inception mimari ailesini geliştirmenin mümkün olabileceği ifade edilmiştir (Chollet, 2017).

Ağın özelliklerinin detaylı haliyle gösterimi Şekil 4.29'da verilmiştir. Xception mimarisi, ağın özellik çıkarma tabanını oluşturan 36 evrişim katmanına sahiptir. 36 evrişim katmanı, ilk ve son modüller hariç, hepsinin çevresinde doğrusal artık bağlantılara sahip olan 14 modül halinde yapılandırılmıştır.



Şekil 4.29. Xception mimarisi (Giriş-Orta-Çıkış akışı) (Chollet, 2017)

Xception mimarisi, artık bağlantılara sahip, derinlemesine ayrılabilir evrişim katmanlarının doğrusal bir yığındır. Bu, mimariyi tanımlamayı ve değiştirmeyi çok kolaylaştırmaktadır. Keras veya TensorFlow-Slim gibi üst düzey bir kitaplık kullanarak yalnızca 30 ile 40 satır kod almakta olup hem bu kodları VGG gibi bir mimariden temin etmemekte hem de Inception V2 veya V3 gibi tanımlanması çok daha karmaşık mimarilerden farklıdır (Chollet, 2017).

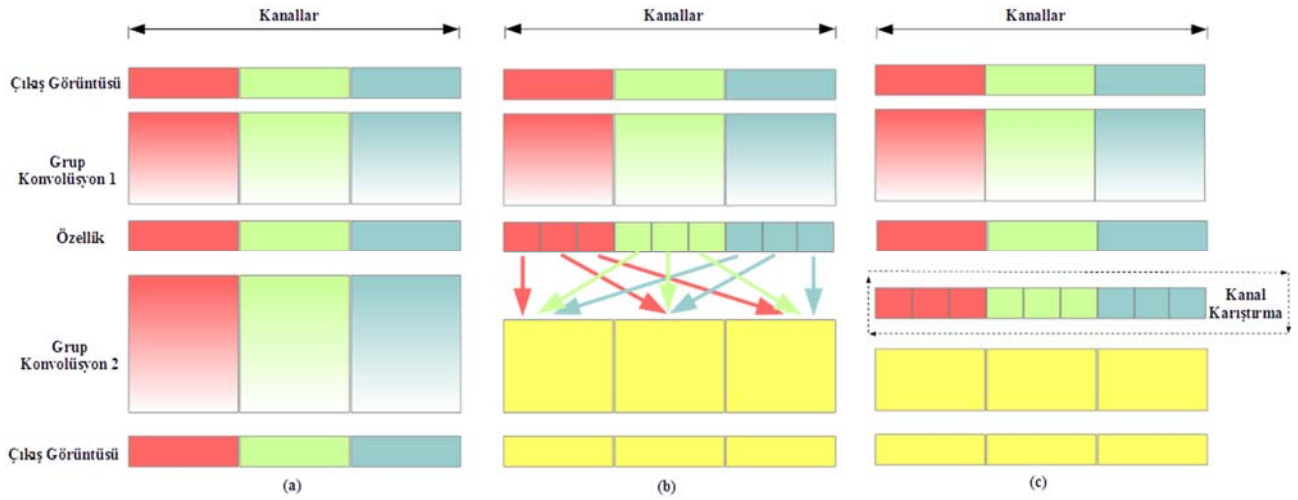
4.3.6. ShuffleNet

Zhang ve ark. (2017) tarafından çok sınırlı bilgi işlem gücüne sahip mobil cihazlar için özel olarak tasarlanmış olan ShuffleNet mimarisi analiz kabiliyeti açısından son derece verimli bir CNN yapısıdır.

Modern CNN'ler genellikle aynı yapıya sahip tekrarlanan yapı taşlarından oluşmaktadır. Bunların arasında, Xception ve ResNeXt gibi son teknoloji ağlar, temsil yeteneği ve hesaplama süresi arasında mükemmel bir denge sağlamak için yapı taşlarına verimli derinlemesine ayrılabilir evrişimler veya grup evrişimleri sunmaktadır. Ancak, her iki tasarımın da önemli ölçüde karmaşıklık gerektiren 1×1 evrişimleri (noktasal evrişimler de denir) tam olarak hesaba katılmadığı Zhang ve ark. tarafından fark edilmiştir. (Örneğin, ResNeXt'te sadece 3×3 katman grup kıvrımları ile donatılmıştır.) Küçük ağlarda, noktasal konvolüsyonlar, doğruluğa önemli ölçüde zarar verebilecek karmaşıklık kısıtlamasını karşılamak için sınırlı sayıda kanalla sonuçlanmaktadır. Sorunu çözmek için basit bir çözüm olan kanalın seyrek bağlantılarını, örneğin grup evrişimlerini de 1×1 katmanlarda uygulamak gerekmektedir. Her bir evrişimin yalnızca karşılık gelen giriş kanalı grubunda çalışmasını sağlayarak grup evrişimi hesaplama süresi önemli ölçüde azaltılmıştır. Bununla birlikte, birden çok grup evrişimlerinin bir araya toplanması neticesinde olumsuz bir sonuç da ortaya çıkmaktadır ki bu, belirli bir kanaldan gelen çıktılar, giriş kanallarının yalnızca küçük bir kısmından türetilmesi sorunudur. Şekil 4.30(a)'da istiflenmiş iki grup evrişim katmanının durumu gösterilmektedir. Belli bir grubun çıktılarının sadece grup içindeki girdilerle ilgili olduğu açık olup bu özellik, kanal grupları arasındaki bilgi akışını engellemekte ve gösterimi zayıflatmaktadır (Zhang ve ark., 2017).

Grup evrişiminin farklı gruplardan girdi verileri elde etmesine izin verilmesi durumunda (Şekil 4.30(b)'de gösterildiği gibi), girdi ve çıktı kanalları tamamen ilişkili olacaktır. Spesifik olarak, önceki grup katmanından oluşturulan özellik haritası için, önce her gruptaki kanalları birkaç alt gruba ayırabilir, ardından sonraki katmandaki her grubu farklı alt gruplarla besleyebilir. Bu, bir kanal karıştırma işlemi ile verimli bir şekilde gerçekleştirilebilir (Şekil 4.30 (c)). Çıktısı $g \times n$ kanalları olan g gruplarına sahip evrişimli bir katman varsayalım; ilk önce çıkış kanalı boyutunu (g, n) olarak yeniden şekillendiririz, transpoze ederiz ve ardından bir sonraki katmanın girişi olarak düzleştiririz. İki evrişimde farklı sayıda grup olsa bile işlemin hala etkili olduğu unutulmamalıdır. Ayrıca, kanal karıştırma da farklılaştırılabilir, bu da uçtan uca eğitim için ağ yapılarına yerleştirilebileceği anlamına gelmektedir (Zhang ve ark., 2017).

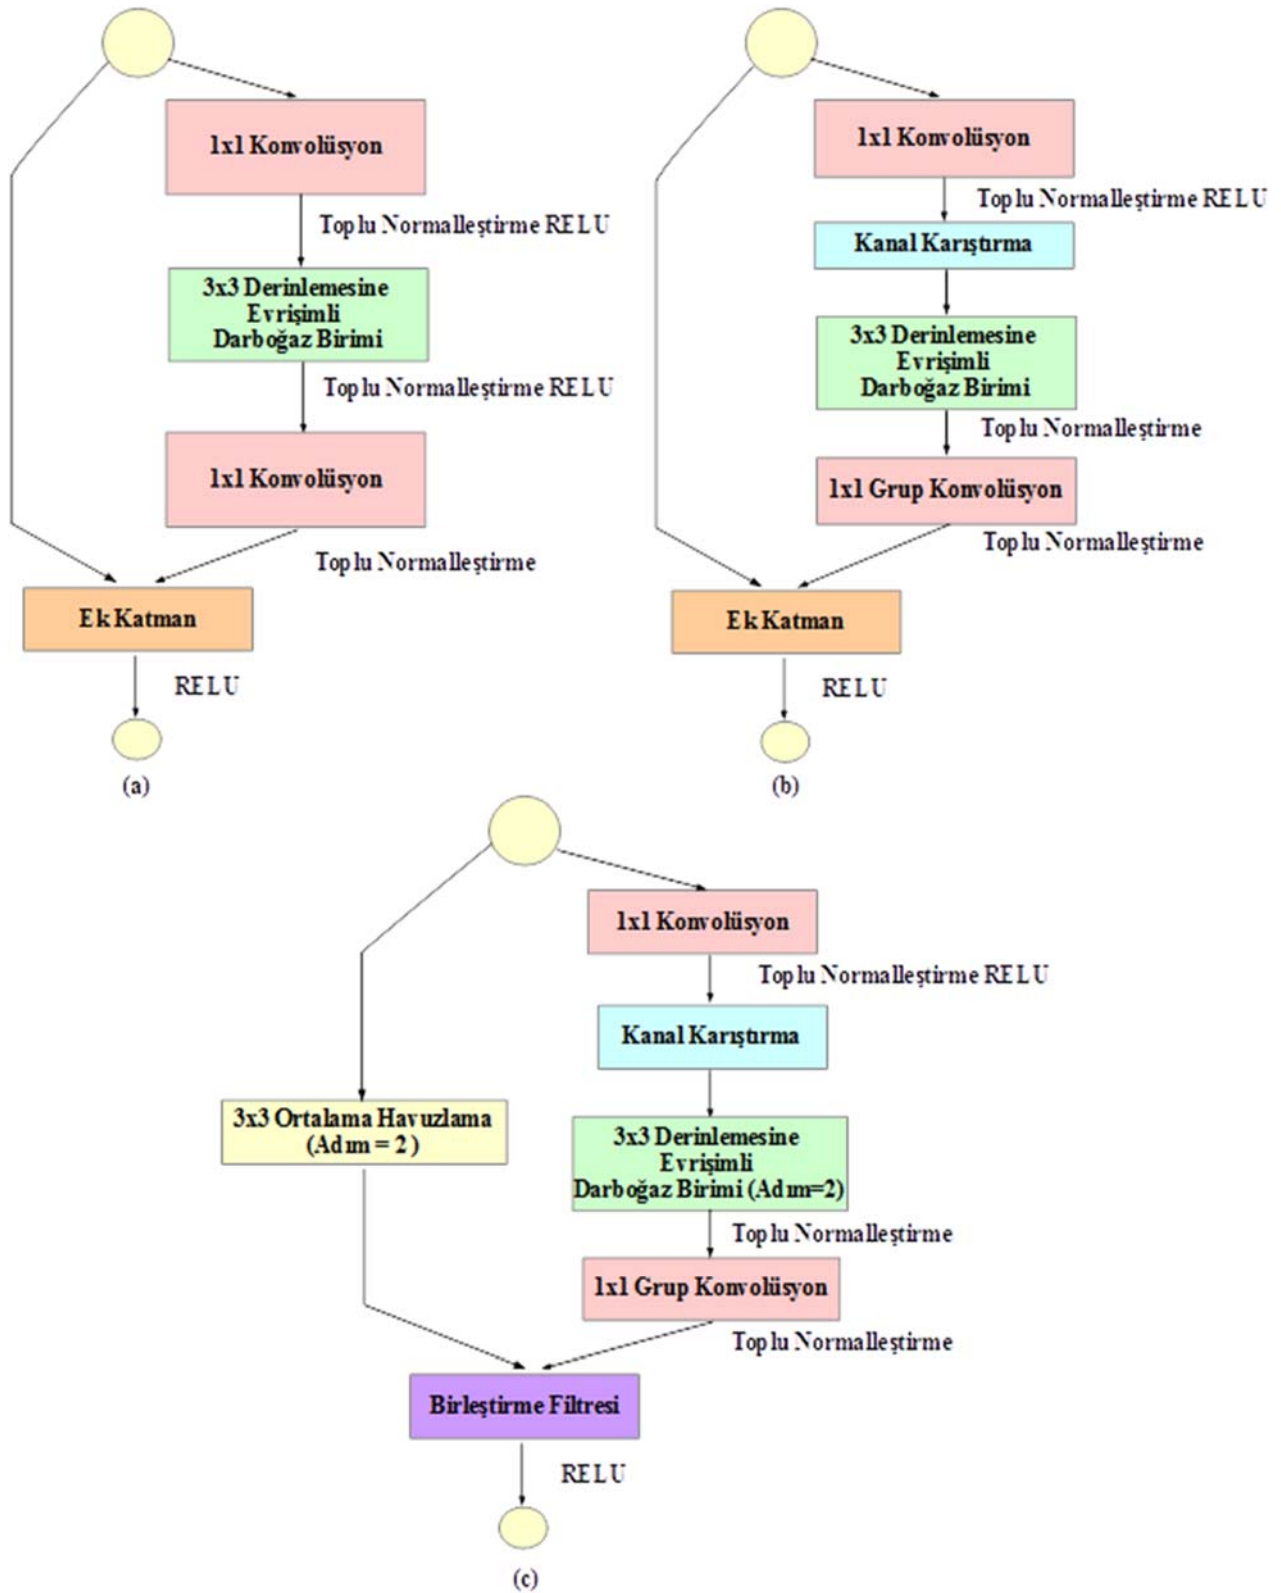
Ayrıca, kanal karıştırma işlemi, çoklu grup evrişim katmanlarıyla daha güçlü yapılar oluşturmayı da mümkün kılmaktadır.



Şekil 4.30. Yığılmış iki grup kıvrımı ile kanal karıştırma işlemi (Zhang ve ark., 2017)

Şekil 4.30(a)'da aynı sayıda gruba sahip iki yığılmış evrişim katmanı verilmiştir. Her çıkış kanalı, yalnızca grup içindeki giriş kanallarıyla ilgilidir. Çaprazlama yoktur. Şekil 4.30(b)'de Grup Konvolüsyon 2'nin, Grup Konvolüsyon 1'den sonra farklı gruplardan veri aldığı giriş ve çıkış kanallarının tamamen ilişkili olduğu gösterilmiştir. Şekil 4.30(c)'de kanal karıştırma kullanarak Şekil 4.30(b)'deki duruma eş değer bir durum elde edildiği gösterilmiştir.

Kanal karıştırma işleminden yararlanarak küçük ağlar için özel olarak tasarlanmış yeni bir ShuffleNet birimi önerilmiştir. Şekil 4.31(a)'daki darboğaz ünitesinin tasarım prensibini incelediğimizde, bu artık bir blok olarak karşımıza çıkmaktadır. Artık dalında, 3×3 katman için, darboğaz öznitelik haritasına 3×3 derinlik yönünde evrişim uygulanmıştır. Ardından, Şekil 4.31(b)'de gösterildiği gibi bir ShuffleNet birimi oluşturmak için ilk 1×1 katmanı noktasal grup evrişimi ve ardından bir kanal karıştırma işlemi ile değiştirilmiştir. İkinci noktasal grup evrişiminin amacı, kısayol yoluna uyması için kanal boyutunu kurtarmaktır. Basit olması için, karşılaştırılabilir puanlarla sonuçlandırıldığından, ikinci noktasal katmandan sonra ekstra bir kanal karıştırma işlemi uygulanmamıştır. Toplu normalleştirme (BN) ve doğrusal olmama kullanımı, derinlemesine evrişimden sonra ReLU kullanılmaması dışında benzerdir. ShuffleNet'in adım adım uygulandığı duruma gelince, sadece iki değişiklik yapılmıştır (Şekil 4.31(c)): (i) kısayol yoluna 3×3 ortalama bir havuzlama eklenmiş; (ii) eleman bazında ekleme işlemi kanal birleştirme ile değiştirilmiştir, bu da kanal boyutunu çok az ilave hesaplama süresi ile büyütmeyi kolaylaştırmıştır (Zhang ve ark., 2017)).



Şekil 4.31. ShuffleNet birimi (Zhang ve ark., 2017)

Şekil 4.31(a)'da derinlemesine evrişimli darboğaz birimi verilmiştir. Şekil 4.31(b)'de noktasal grup evrişimli ve kanal karıştırmalı ShuffleNet birimi verilmiştir. Şekil 4.31(c)'de adımlı ShuffleNet birimi verilmiştir.

Çizelge 4.6. ShuffleNet mimarisi

Layer (Tür)	Çıktı Boyutu	Filtre Boyutu	Stride	Tekrar
Giriş Görüntüsü	224 x224 x3			
Conv_1	112 x112	3 x3	2	1
Maxpool	56 x56	3 x3	2	
Stage 2	28 x28		2	1
	28 x28		1	3
Stage 3	14 x14		2	1
	14 x14		1	7
Stage 4	7 x7		2	1
	7 x7		1	3
Global Pool	1x1	7 x7		
FC (Tam Bağlı)	1x1 x1000			

ShuffleNet birimleri üzerine kurulu, genel ShuffleNet mimarisi Çizelge 4.6'da verilmiştir. Önerilen ağ esas olarak üç aşamada gruplandırılmış bir ShuffleNet birimleri yığınınından oluşmaktadır. Her aşamadaki ilk yapı bloğu adım = 2 ile uygulanır. Bir aşamadaki diğer hiper parametreler aynı kalır ve bir sonraki aşama için çıkış kanalları iki katına çıkar. Benzer şekilde, darboğaz kanallarının sayısı her ShuffleNet birimi için çıkış kanallarının 1/4'üne ayarlanmıştır. Burada amaç, daha fazla hiperparametre düzenlemesinin daha iyi sonuçlar üretebileceğini bulmak ve bunu yaparken de mümkün olduğunca basit bir tasarım sağlamaktır (Zhang ve ark., 2017).

4.3.7. DarkNet-53

DarkNet-53, ImageNet üzerinde eğitilmiş 53 katmandan (konvolüsyon) oluşan ve yaklaşık 40,6 milyon nöronu bünyesinde barındıran bir Ön Eğitimli KSA yapısıdır. Çizelge 4.7'de DarkNet-53 mimarisinin genel yapısı verilmiştir.

Çizelge 4.7. DarkNet-53 mimarisi

Layer (Tür)	Çıktı Boyutu	Filtre Boyutu	Stride	Tekrar
Giriş görüntüsü	224x224x3			
Conv.	256x256	3x3 32		
Conv.	128x128	3x3 64	2	
Conv.		1x1 32		
Conv.		3x3 64		1
Residual	128x128			
Conv.	64x64	3x3 128	2	
Conv.		1x1 64		
Conv.		3x3 128		2
Residual	64x64			

Conv.	32x32	3x3 256	2
Conv.		1x1 128	
Conv.		3x3 256	8
Residual	32x32		
Conv.	16x16	3x3 512	2
Conv.		1x1 256	
Conv.		3x3 512	8
Residual	16x16		
Conv.	8x8	3x3 1024	2
Conv.		1x1 512	
Conv.		3x3 1024	4
Residual	8x8		
Global Pool	1x1	1 x1 1024	
FC-Softmax	1x1 x1000		

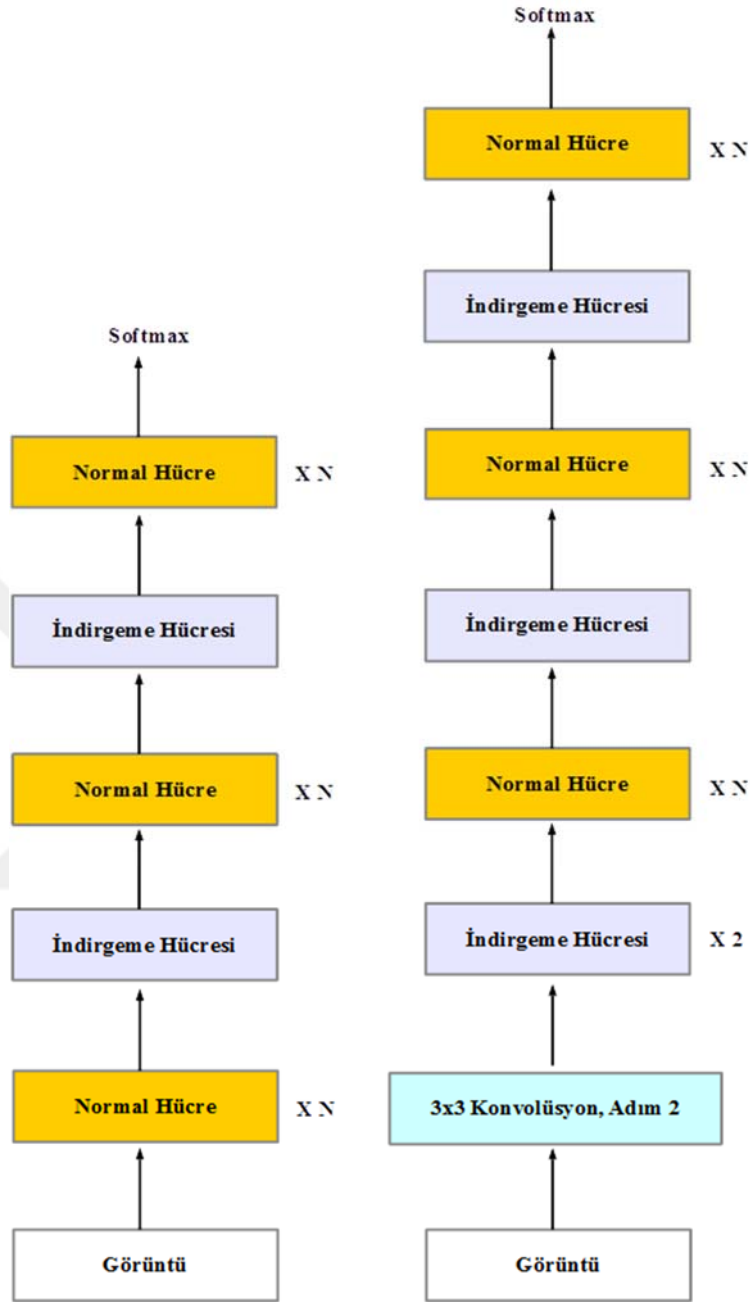
4.3.8. NasNet Large

NasNetLarge, ölçeklenebilir görüntü tanıma için aktarılabılır mimarileri öğrenmek amacıyla Google'ın yapay zekâya adanmış bir araştırma bölümü olan Google Brain (2018) tarafından geliştirilmiş bir Ön Eğitimli KSA mimarisidir. NASNet mimarisi, küçük model boyutu ve düşük karmaşıklık (FLOP'lar) ile son teknoloji ürünü sonuçlara ulaşan bir yapıdır.

Bu KSA yapısında, ilgilenilen bir veri kümesinde iyi evrimsel mimariler bulmak için arama Yöntemleri kullanılmıştır. Bu çalışmada kullanılan ana arama yöntemi, Neural Architecture Search (NAS) çerçevesidir. NAS'ta, bir denetleyici tekrarlayan sinir ağı, farklı mimarilere sahip alt ağları örnekler. Alt ağlar, uzatılmış bir doğrulama setinde bir miktar doğruluk elde etmek için yakınsama amacıyla eğitilmiştir. Ortaya çıkan doğruluklar, denetleyiciyi güncellemek için kullanılmakta ve böylece denetleyici zaman içinde daha iyi mimariler oluşturmaktadır (Zoph ve ark., 2018).

Söz konusu KSA yapısında, evrimsel ağların genel mimarileri manuel olarak önceden belirlenmektedir. Her bir evrişim hücresi aynı mimariye, ancak farklı ağırlıklara sahip olup birçok kez tekrarlanan evrişim hücrelerinden oluşmaktadır. Herhangi bir boyuttaki görüntüler için kolayca ölçeklenebilir mimariler oluşturmak için, bir özellik haritasını girdi olarak alırken iki ana işleve hizmet edecek iki tür evrişim hücresine ihtiyaç bulunmaktadır: (1) aynı boyutta bir özellik haritası döndüren evrişim hücreleri ve (2) özellik haritası yüksekliği ve genişliğinin iki kat azaltıldığı bir özellik haritası döndüren evrişim hücreleri. Evrimsel hücrelerin birinci tipi ve ikinci tipi sırasıyla Normal Hücre ve Redüksiyon (İndirgeme) Hücresi olarak adlandırılmaktadır. İndirgeme Hücresi için, yüksekliği ve genişliği azaltmak amacıyla hücrenin girişlerine uygulanan ilk işlem iki adımlı hale

getirilmiştir. Tüm evrişimli hücreleri oluşturmak için yapılan her işlemde adım atma seçeneği bulunmaktadır (Zoph ve ark., 2018).



Şekil 4.32. CIFAR-10 ve ImageNet mimarileri

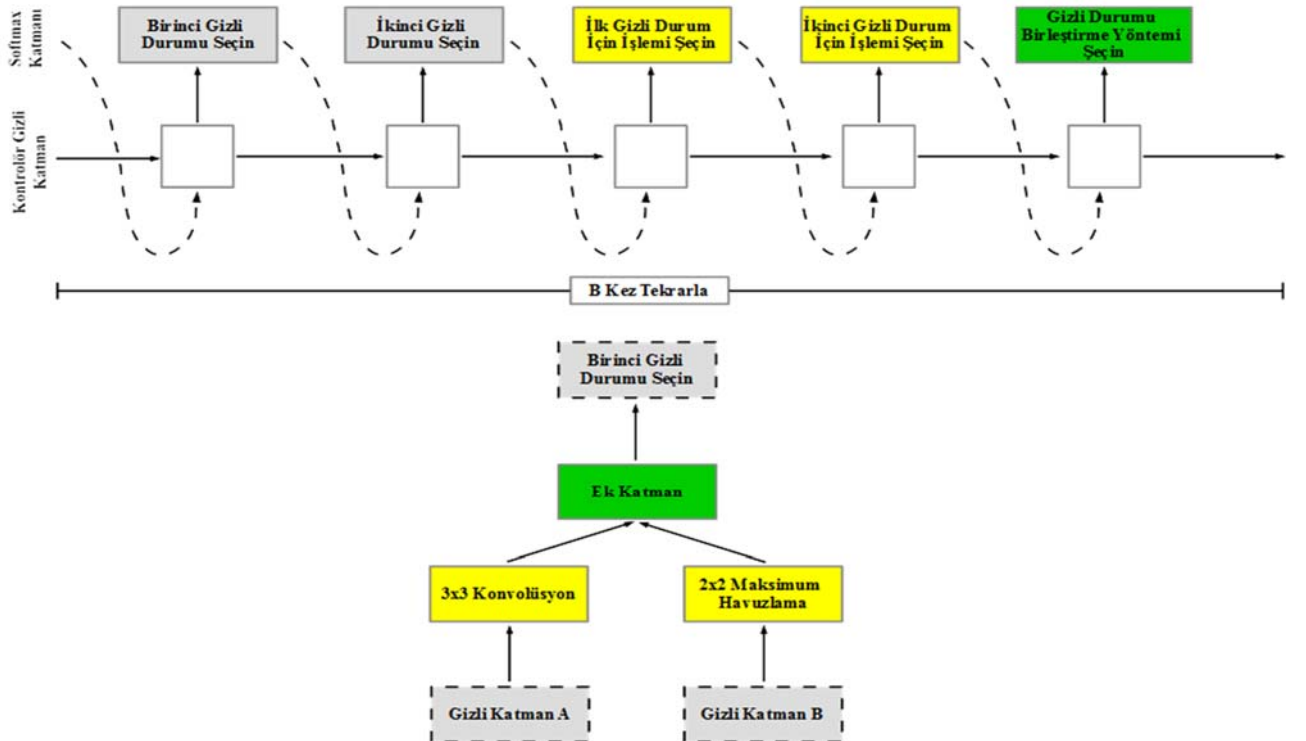
Şekil 4.32’de görüntü sınıflandırması için ölçeklenebilir mimarilerin, Normal Hücre ve İndirgeme Hücresi olarak adlandırılan iki tekrarlanan motiften oluştuğu gösterilmiştir.

Şekil 4.32’de, CIFAR-10 (sol) ve ImageNet (sağ) için Normal ve İndirgeme Hücrelerinin yerleşimi gösterilmektedir. CIFAR için 32x32’ye kıyasla gelen görüntü boyutu 299x299 olduğundan, ImageNet’te daha fazla küçültme hücrelerine ihtiyaç duyulmaktadır. İndirgeme ve Normal Hücre aynı mimariye sahip olabileceği gibi ayrı mimariler olarak da tasarlanabilir. Kabaca sabit gizli durum boyutunu korumak için uzamsal etkinleştirme boyutu her azaltıldığında çıktındaki filtre sayısını ikiye katlamak için ortak bir yöntem kullanılmıştır. Daha da önemlisi, Inception ve

ResNet modellerinde olduğu gibi, motif tekrarlarının sayısı N ve ilk konvolüsyonel filtrelerin sayısı bir görüntü sınıflandırma probleminin ölçeğine göre uyarlanan serbest parametreler olarak kabul edilmiştir (Zoph ve ark., 2018).

Evrişimli ağlarda değişen, kontrolör RNN (Yinelemeli Sinir Ağı) tarafından aranan Normal ve İndirgeme Hücrelerinin yapılarıdır. Arama uzayında her hücre, önceki iki alt katmandaki iki hücrenin çıktıları veya girdi görüntüsü olan h_i ve h_{i-1} olmak üzere iki başlangıç gizli durumunu girdi olarak almaktadır. RNN denetleyicisi, bu iki ilk gizli durum göz önüne alındığında, evrişimli hücrenin yapısının geri kalanını yinelemeli olarak tahmin etmektedir (Şekil 4.33). Her hücre için denetleyicinin tahminleri her bloğun, bir bloğun öğelerinin ayrık seçimlerine karşılık gelen 5 farklı softmax sınıflandırıcı tarafından yapılan 5 tahmin adımına sahip olduğu B blokları halinde gruplandırılmıştır:

- h_i ve h_{i-1} veya önceki bloklarda oluşturulan gizli durumlar kümesinden bir gizli durum seçilir.
- Adım 1'deki ile aynı seçeneklerden ikinci bir gizli durum seçilir.
- Adım 1'de seçilen gizli duruma uygulanacak bir işlem seçilir.
- Adım 2'de seçilen gizli duruma uygulanacak bir işlem seçilir.
- Yeni bir gizli durum oluşturmak için Adım 3 ve 4'ün çıktılarını birleştirmek için bir yöntem seçilir.



Şekil 4.33. Evrişimli bir hücrenin bir bloğunu yinelemeli olarak oluşturmak için denetleyici model mimarisi

Şekil 4.33'te her blokun her biri bir softmax katmanının çıktısına karşılık gelen 5 ayrı parametrenin seçilmesinin gerektiği gösterilmektedir. Şekil 4.33'te gösterilen örnek oluşturulmuş bir bloktur. Evrişimli bir hücre B blokları içermekte olup dolayısıyla kontrolör bir evrişimli hücrenin mimarisini tahmin etmek için 5B softmax katmanlarını içermektedir. Söz konusu KSA yapısında B blok sayısı 5 olarak alınmıştır.

Algoritma, yeni oluşturulan gizli durumu, sonraki bloklarda potansiyel bir girdi olarak mevcut gizli durumlar kümesine eklemektedir. Kontrolör RNN, bir evrişimli hücrede B bloklarına karşılık gelen yukarıdaki 5 tahmin adımını B kez tekrarlamaktadır.

3. ve 4. adımlarda, denetleyici RNN gizli durumlara uygulanacak bir işlemi seçmektedir. Bu KSA yapısında CNN literatüründeki yaygınlıklarına göre aşağıdaki işlemler gerçekleştirilmektedir.

- Giriş Görüntüsü ($331 \times 331 \times 3$)
- 1×7 ve ardından 7×1 konvolüsyon işlemi
- 3×3 ortalama havuzlama işlemi
- 5×5 maksimum havuzlama işlemi
- 1×1 konvolüsyon işlemi
- 3×3 derinlemesine ayrılabilir evrişim işlemi (standart bir evrişim; kanal ve uzamsal hesaplamayı tek adımda gerçekleştirirken, derinlemesine ayrılabilir evrişim, hesaplamayı iki adıma böler: derinlemesine evrişim her giriş kanalı için tek bir evrişim filtresi uygular ve noktasal evrişim, çıktının doğrusal bir kombinasyonunu oluşturmak için kullanılır.)
- 7×7 derinlemesine ayrılabilir (depth seperable) evrişim işlemi
- 1×3 ve ardından 3×1 konvolüsyon işlemi
- 3×3 genişletilmiş (dilated) evrişim (çekirdek elemanları arasına delikler yerleştirilerek çekirdeği şişiren bir evrişim türüdür.)
- 3×3 maksimum havuzlama işlemi
- 7×7 maksimum havuzlama işlemi
- 3×3 konvolüsyon işlemi
- 5×5 derinlemesine ayrılabilir evrişim işlemi

Adım 5'te denetleyici RNN, iki gizli durumu birleştirmek için bir yöntem seçer, ya iki gizli durum arasında eleman bazında ekleme yapar, ya da filtre boyutu boyunca iki gizli durum arasında birleştirme yapar. Son olarak, evrişimli hücrede üretilen kullanılmayan gizli durumların tümü, nihai hücre çıktısını sağlamak için derinlemesine bir araya getirilir (Zoph ve ark., 2018).

Kontrolör RNN'nin hem Normal Hücreyi hem de İndirgeme Hücrelerini tahmin etmesine izin vermek için, kontrolörün toplamda $2 \times 5B$ tahminleri olması sağlanır ve burada ilk 5B tahminleri Normal Hücre için ve ikinci 5B tahminleri İndirgeme Hücreleri için yapılır.

Ayrıca, bu KSA yapısında NAS'taki pekiştirmeli öğrenme önerisi kullanılmıştır. Bununla birlikte NASNet arama alanındaki mimarileri aramak için rastgele aramayı kullanmak da mümkündür.

4.3.9. EfficientNet

EfficientNet modeli, Google araştırma ekibinden Tan ve Le (2019) tarafından ortaya atılmış Ön Eğitimli KSA modelidir. Bu araştırmacılar, KSA model ölçeklendirilmesini incelemiş ve ağın derinliğinin, genişliğinin ve çözünürlüğünün ölçeklendirilmesinde dengelemenin, ağ performansını etkilediğini belirlemişlerdir. Bu gözlem temelinde; ağın derinlik, genişlik ve çözünürlüğünün tüm boyutlarını eşit olarak ölçekleyen yeni bir ölçeklendirme yöntemi önermişlerdir (Kumar 2020). EfficientNet, B0'dan B7'ye kadar 8 tane modelden oluşmaktadır. Model büyüdükçe kullanılan parametre sayısı ve başarı oranı artmaktadır. Yapılacak çalışmaya göre öncelikle temel model olan EfficientNet-B0 oluşturulur. Daha sonra doğruluğu ve model boyutunu artırmak için temel model, bileşik ölçeklendirme ile EfficientNet-B1'den, EfficientNet-B7'ye kadar büyütülebilir. Her artışta işlem gücü, yaklaşık iki katına çıkmaktadır (Kızrak 2019). EfficientNet-B0 için genel mimari yapı Çizelge 4.8'de verilmiştir. Çizelge 4.8'de verilen MBConvolution mobil ters çevrilmiş darboğaz evrişimidir.

Çizelge 4.8. EfficientNet-B0 mimarisi


Aşama (i)	Layer (Tür)	Çıktı Boyutu	Filtre Boyutu	Katman Sayısı
1	Conv.3x3	224 x224	32	1
2	MBConv.1, k3x3	112 x112	16	1
3	MBConv.6, k3x3	112 x112	24	2
4	MBConv.6, k5x5	56 x56	40	2
5	MBConv.6, k5x5	28 x28	80	3
6	MBConv.6, k5x5	28 x28	112	3
7	MBConv.6, k5x5	14 x14	192	4
8	MBConv.6, k3x3	7x7	320	1
9	Conv.1x1, Avg Pool, FC	7 x7	1280	1

Önceki ölçekleme çalışmalarında; derinlik, genişlik ve çözünürlük parametrelerinden genellikle yalnızca biri ölçeklenmektedir. Ağı derinliği, bir ağıdaki katman sayısına karşılık gelmektedir. Genişlik, bir konvolüsyonel katmandaki filtrelerin sayısı ile ilişkilidir. Çözünürlük ise, giriş görüntüsünün yüksekliği ve genişliğidir. İki veya üç parametreyi keyfi olarak ölçeklemek mümkün olsa da keyfi ölçekleme zahmetli manuel ayar gerektirmektedir ve buna rağmen çoğu zaman istenilen verimlilik ve doğruluk elde edilemez. Önerilen EfficientNet modeli yalnızca daha

yüksek doğruluk sağlamakla kalmamakta, aynı zamanda son teknoloji modellere kıyasla parametreleri azaltarak modellerin verimliliğini de artırmaktadır (Tan ve Le 2019, Shahid 2020).

EfficientNet modeliyle parametreleri rastgele ölçekleyen geleneksel uygulamanın aksine, ağ genişliğinin, derinliğinin ve çözünürlüğünün bileşik ölçeklendirme (compound scaling) ile bir dizi sabit ölçekleme katsayısı ile eşit şekilde ölçeklendirilmesi önerilmiştir. Örneğin, $2N$ kat daha fazla hesaplama kaynağı kullanmak istenildiğinde; o zaman ağ derinliği αN , genişliği βN ve görüntü boyutu γN artırılabilir, burada α , β , γ model üzerinde grid arama yöntemiyle belirlenen sabit katsayılardır (Tan ve Le 2019). EfficientNet modelinde önerilen bileşik ölçeklendirme yöntemi Şekil 4.34'te verilmiştir.

Diğer taraftan, daha çok konvolüsyonel katman ekleyerek derinliği artırmak, ağı daha karmaşık özellikleri öğrenmesine olanak tanımaktadır. Ancak daha derin ağlar, yok olan gradyanlar sebebiyle sorun çıkarmakta ve ağı eğitimi zorlaştırmaktadır. Toplu normalizasyon ve atlama bağlantıları gibi yeni teknikler bu sorunu çözmede etkili olsa da deneysel çalışmalar, yalnızca ağı derinliğini artırmanın doğruluk artış oranını artırdığını göstermektedir.



Şekil 4.34. a) Temel ağ örneği, b)-d) ağ genişliğinin, derinliğinin veya çözünürlüğünün yalnızca bir boyutunu artıran geleneksel ölçeklendirmeler, e) EfficientNet'in bileşik ölçeklendirme yöntemi (Kızrak, 2019)

4.4. Konvolüsyonel Sınır Ağlarını Değerlendirmek için Kullanılan Metrikler

CNN'leri değerlendirmek herhangi bir çalışmanın neticelerinin yorumlanması açısından önemli bir husus olarak karşımıza çıkmaktadır. Bir CNN yapısı; örneğin doğruluk skoru gibi bir metrik kullanılarak değerlendirildiğinde tatmin edici sonuçlar verebilir, ancak logaritmik kayıp veya benzeri herhangi bir metrik gibi diğer metriklerle karşı değerlendirildiğinde kötü sonuçlar verebildiği de göz önünde bulundurulmalıdır (Mishra, 2018).

CNN'lerin performansını ölçmek için çoğu zaman sınıflandırma doğruluğu kullanılmaktadır. Ancak bu, söz konusu yapıları gerçekten değerlendirmek için yeterli olmayabilir. Aşağıda mevcut olan farklı değerlendirme metrikleri anlatılmaktadır.

Sınıflandırma Doğruluğu: Doğruluk terimi kullanıldığında genellikle kastedilen şeydir. Doğru tahmin sayısının toplam girdi örneği sayısına oranıdır (Denk 4.7).

$$\text{Doğruluk} = \frac{\text{Doğru Tahmin Sayısı}}{\text{Toplam Girdi Sayısı}} \quad (4.7)$$

Logaritmik Kayıp: Yanlış sınıflandırmaları cezalandırarak çalışır. Çok sınıflı sınıflandırma için iyi çalışan bir metriktir. Bu metrikte sınıflandırıcı, tüm örnekler için her sınıfa olasılık atmalıdır. M sınıfa ait N adet örnek olduğunu varsayarsak logaritmik kayıp Denklem 4.8'deki gibi hesaplanır.

$$\text{Logaritmik Kayıp} = \frac{-1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \times \log(p_{ij}) \quad (4.8)$$

(y_{ij} : i örneğinin j sınıfına ait olup olmadığını gösterir, p_{ij} : j sınıfına ait olan i örneğinin olasılığını gösterir.)

Kayıp fonksiyonunun üst sınırı yoktur ve $[0, \infty)$ aralığında bulunur. 0'a yakın logaritmik kayıp daha yüksek doğruluğu gösterirken logaritmik kayıp 0'dan uzaktaysa daha düşük doğruluğu göstermektedir.

Karışıklık Matrisi: Gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir yöntemdir. Karışıklık matrisi aynı zamanda diğer metrik türlerinin temelini de oluşturmaktadır. Burada, 4 önemli terim vardır. Bunları ikili sınıflandırma özelinde Evet ya da Hayır olarak değerlendirdiğimizi düşünürsek:

- Gerçek Pozitif: Evet tahmin edilen ve gerçek çıktının da Evet olduğu durumlar.
- Gerçek Negatif: Hayır öngörülen ve gerçek çıktının Hayır olduğu durumlar.
- Yanlış Pozitif: Evet tahmin edilen ve gerçek çıktının Hayır olduğu durumlar.
- Yanlış Negatif: Hayır öngörülen ve gerçek çıktının Evet olduğu durumlar.

Matrisin doğruluğu Denklem 4.9. ile hesaplanmaktadır.

$$\text{Doğruluk} = \frac{\text{Gerçek Pozitif} + \text{Gerçek Negatif}}{\text{Toplam Örnek}} \quad (4.9)$$

Eğri Altındaki Alan: Değerlendirme için en yaygın kullanılan metriklerden biridir. İkili sınıflandırma problemi için sıklıkla kullanılır. Bir sınıflandırıcının eğri altında kalan alanı, sınıflandırıcının rastgele seçilen bir pozitif örneği, rastgele seçilen bir negatif örnekten daha yüksek sıraya koyma olasılığına eşittir. Eğri altında kalan alanı tanımlamadan önce aşağıdaki temel terimleri tanımlamak gerekmektedir. Bu terimler Denklem 4.10, Denklem 4.11. ve Denklem 4.12. aracılığıyla verilmiştir.

$$\text{Gerçek Pozitif Oran (Hassasiyet)} = \frac{\text{Gerçek Pozitif}}{\text{Yanlış Negatif} + \text{Gerçek Pozitif}} \quad (4.10)$$

$$\text{Gerçek Negatif Oran (Özgüllük)} = \frac{\text{Gerçek Negatif}}{\text{Gerçek Negatif} + \text{Yanlış Pozitif}} \quad (4.11)$$

$$\text{Yanlış Pozitif Oran} = \frac{\text{Yanlış Pozitif}}{\text{Yanlış Pozitif} + \text{Gerçek Negatif}} \quad (4.12)$$

Yanlış Pozitif Oran ve Gerçek Pozitif Oranın her ikisi de $[0, 1]$ aralığında değerlere sahiptir. Değer ne kadar büyük olursa algoritmanın performansı o kadar iyi olmaktadır.

F1 Puanı: Kesinlik ve duyarlılık arasındaki harmonik ortalamadır. F1 Puan aralığı $[0, 1]$ 'dir. Sınıflandırıcının ne kadar hassas olduğunu ve bunun yanı sıra ne kadar sağlam olduğunu oldukça doğru bir şekilde ortaya koyar. Yüksek hassasiyet daha düşük duyarlılık ve kesinlik sağlamaktadır, fakat sınıflandırılması zor olan çok sayıda örneği gözden kaçırmaktadır (Mishra, 2018).

Aynı zamanda F1 skoru, kesinlik ve duyarlılık arasındaki dengeyi bulmaya çalışmaktadır. F1 puanı ne kadar yüksek olursa model performansı o kadar iyi olmaktadır. Matematiksel olarak Denklem 4.13. ile ifade edilmektedir.

$$F1 = 2 \times \frac{1}{\frac{1}{\text{Kesinlik}} + \frac{1}{\text{Duyarlılık}}} \quad (4.13)$$

Kesinlik: Sınıflandırıcı tarafından tahmin edilen pozitif sonuç sayısına bölünen doğru pozitif sonuç sayısıdır (Denk 4.14).

$$\text{Kesinlik} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Yanlış Pozitif}} \quad (4.14)$$

Duyarlılık: Doğru pozitif sonuçların sayısının tüm örneklerin (pozitif olarak tanımlanması gereken tüm örneklerin) sayısına bölünmesiyle elde edilen değerdir (Denk 4.15).

$$\text{Duyarlılık} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Yanlış Negatif}} \quad (4.15)$$

Ortalama Mutlak Hata: Ölçülen değerler ile öngörülen değerler arasındaki farkın ortalamasıdır. Tahminlerin gerçek çıktıdan ne kadar uzak olduğunun ölçüsünü verir. Ancak hatanın yönü hakkında herhangi bir fikir vermezler, yani verinin eksik mi yoksa fazla mı tahmin edildiğine dair bir fikir vermezler (Mishra, 2018). Matematiksel olarak Denklem 4.16. ile ifade edilmektedir.

$$\text{Ortalama Mutlak Hata} = \frac{1}{N} \sum_{j=1}^N |y_j - \tilde{y}_j| \quad (4.16)$$

(y_j : Ölçülen değer, \tilde{y}_j : Öngörülen değer)

Ortalama Kare Hata: Ortalama mutlak hatadan tek farkı ölçülen değerler ile tahmin edilen değerler arasındaki farkın karesinin ortalamasını almasıdır. Bunun avantajı ise gradyanı hesaplamının daha kolay olmasıdır. Oysa ortalama mutlak hata, gradyanı hesaplamak için karmaşık doğrusal programlama araçları gerektirmektedir. Hatanın karesi alındığında daha büyük hataların etkisi daha küçük hatalardan daha belirgin hale gelmekte ve dolayısıyla model artık daha büyük hatalara daha fazla odaklanabilmektedir (Mishra, 2018). Matematiksel olarak Denklem 4.17. ile ifade edilmektedir.

$$\text{Ortalama Kare Hata} = \frac{1}{N} \sum_{j=1}^N (y_j - \tilde{y}_j)^2 \quad (4.17)$$

(y_j : Ölçülen değer, \tilde{y}_j : Öngörülen değer)

Bu tez çalışmasında; sınıflandırma doğruluğu ve logaritmik kayıp fonksiyonları kullanılmak suretiyle değerlendirme işlemleri gerçekleştirilmiştir.

5. MATERYAL VE YÖNTEM

Bu tez çalışmasında, mevcut betonarme binaların deprem risk değerlendirmelerinin hızlı bir şekilde yapılmasına olanak sağlayan, sismik risk parametrelerinden; ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi durumunun belirlenmesine yönelik DÖ'ye ve görüntü işlemeyle dayalı 10 adet Ön Eğitimli KSA yapısı (DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50) ikili sınıflandırma ve çok sınıflı sınıflandırma prosedürleri kullanılmak suretiyle 4 farklı veri seti üzerinden MATLAB programı aracılığıyla analize tabi tutulmuş ve analiz sonuçları neticesinde söz konusu parametrelerin doğruluk yüzdeleri sınıflandırma doğruluğu ve logaritmik kayıp fonksiyonları kullanılmak suretiyle belirlenerek mukayese edilmiştir. Mukayese edilen Ön Eğitimli KSA yapıları ile mevcut betonarme binaların mümkün olan tüm cephelerinden alınmış olan sokak görüntüleri (Street view) üzerinden olası deprem performansına etki eden parametrelerden olan ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi varlığı durumları belirlenmiştir. Başka bir ifade ile bina cephe görselleri kullanılarak binaların deprem riskinin hızlı bir şekilde belirlenmesinde kullanılan parametrelerden üç tanesi tespit edilmiştir. Bu üç parametrenin seçilmesindeki en önemli etken; bilgisayarlı görü modellerinden Ön Eğitimli KSA yapılarının Google Street View üzerinden toplanan cephe görselleri ile entegre bir şekilde çalışmasında herhangi bir uyum sorunu teşkil etmeyecek olması ile birlikte betonarme binaların hızlı sismik değerlendirmesinde literatürde de önemli bir yer kaplayan ve en çok önem arz eden parametreler arasında yer almasıdır.

Bilgisayarlı görü alanında; son yirmi yılda ikili sınıflandırma (binary classification), çok sınıflı sınıflandırma (multi-class classification) ve Çok Etiketli Sınıflandırma (multi-label classification) olmak üzere birçok görüntü sınıflandırma algoritması geliştirilmiştir. Burada ikili sınıflandırma ile çok sınıflı sınıflandırma mukayese edilirse; ikili sınıflandırma problemlerinde sadece cevabı evet ya da hayır olan soru sorulur, eğer verilecek cevap ikiden fazla değer içinden seçilerek cevaplanacaksa buna çok sınıflı sınıflandırma problemi denilmektedir. Bu tez kapsamında yapılan sınıflandırma kategorilerindeki amaç, giriş görüntüsüne manuel olarak bir etiket atamak ve bahsi geçen Ön Eğitimli KSA yapılarını kullanmak suretiyle MATLAB aracılığıyla manuel olarak atanan bu etiketlerin doğruluğunun yüzdesel olarak belirlenmesini sağlamaktır.

Temel olarak, görüntü sınıflandırma algoritmaları özellik çıkarma (feature extraction) ve sınıflandırma (classification) olmak üzere iki aşamadan oluşur. Geleneksel görüntü sınıflandırma yöntemlerinde, görüntülerden özellikler otomatik olmayan bir şekilde (manuel olarak) çıkarılır. Ama karmaşık senaryolarda, manuel olarak elde edilen özellikler görüntülerdeki nesnelerin özelliklerini tam olarak ifade edemez, bu nedenle düşük sınıflandırma doğruluğuna yol açabilir. Geleneksel yaklaşımların bu sınırlamasıyla başa çıkmak için, son zamanlarda görüntülerden yüksek seviyeli özellikleri otomatik olarak çıkarmak için CNN'lere dayalı birçok sınıflandırma algoritması

geliştirilmiştir. Daha spesifik olarak ifade etmek gerekirse, CNN'lerin geleneksel sınıflandırma yöntemlerine göre temel üstünlükleri, CNN'lerde özellik çıkarma ve sınıflandırmanın aynı aşda kullanılmasıdır. Bu nedenle, bu tez çalışmasında amaç bina cephe görsellerine bağlı birden çok özelliği otomatik olarak elde etmek olduğundan, derin CNN özellik çıkarma prosedürü (feature extraction procedure) kullanılmıştır.

Bugüne kadar karmaşık görüntülerden üst düzey özellikler çıkarmak ve görüntü sınıflandırma görevleri yapabilmek amacıyla Inception, VGG ve ResNet gibi birçok farklı CNN mimarisi geliştirilmiştir. Genel olarak, derin CNN mimarileri; evrişim (konvolüsyon), aktivasyon, havuzlama ve tam bağlı (Convolutional, Activation, Pooling, and Fully Connected-FC) gibi çeşitli katmanlardan oluşur. CNN modelindeki evrişimli katmanın amacı, özellikleri girdi görüntülerinden çıkarmaktır. Her evrişim katmanı, özellik çıkarılmasına yardımcı olan bir dizi filtreye sahiptir. Aktivasyon katmanları, CNN'lerde doğrusal olmama durumunu ortaya çıkarır ve karmaşık senaryoları öğrenmek için modelleme yeteneği getirir. Havuzlama (pooling) katmanı, giriş görüntüsünün boyutunu azaltmak için kullanılır. Görüntüleri sınıflandırmak için ise tam bağlı (FC) katman kullanılır. Son teknoloji ürünü olan CNN mimarileri, sınıflandırma problemlerinde çok sınıflı görüntüler için iyi bir performans gösterse de bina cephe görsellerinde düşünülen çok etiketli sınıflandırma problemleri için tasarlanmamıştır. Bu nedenle, yüksek sınıflandırma doğruluğunun gereksinimlerini karşılamak ve bir binayı sokak görüntülerinden hassas bir şekilde sınıflandırmak için mevcut CNN mimarisini geliştirmek çok önemlidir. Bu tez kapsamında önerilen derin CNN çok etiketli sınıflandırma yöntemi üç adımdan oluşmaktadır. Bu adımlar:

- a) Veri toplama
- b) Veri ön işleme
- c) Derin CNN çoklu etiket sınıflandırmasıdır.

Söz konusu CNN yapısında binaları sokak görüntülerinden doğru bir şekilde sınıflandırmak için mümkün olduğunca farklı şehirlerden 4500 adet bina cephe görseli toplanmak suretiyle 4 farklı veri seti oluşturulmuştur. Söz konusu sokak görüntüleri, bilimsel kullanıma açık bir yazılım olan Google Street View Static API kullanılarak elde edilmiştir. Bahsi geçen erişilebilir (mevcut) cephe görüntüleri CNN algoritmasında ayrı ayrı sınıflandırma yapılmak suretiyle değerlendirme işlemine tabi tutulmuştur. Örneğin binanın tek bir cephe görseli varsa tek bir cephe görseli üzerinden, birden fazla cephe görseli varsa da bu görsellerin her biri için ayrı ayrı değerlendirme yapılmıştır.

Toplanan betonarme binalara ait cephe görsellerinin illere göre dağılımı Çizelge 5.1'de, kat sayıları ise Çizelge 5.2'de verilmiştir. Cephe görseli toplanan illerin coğrafik dağılımının harita üzerinde gösterimi ise Şekil 5.1'de verilmiştir.

Çizelge 5.1. Cephe görsellerinin illere göre dağılımı

Cephe Görseli Toplanan İl	Cephe Görseli Adedi
Ankara	1500
İstanbul	500
İzmir	680
Konya	600
Trabzon	100
Kayseri	200
Niğde	360
Antalya	200
Rize	210
Artvin	50
Balıkesir	100
Toplam	4500



Şekil 5.1. Cephe görseli toplanan illerin coğrafik dağılımı

Çizelge 5.2. Cephe görsellerinin kat adetlerine göre dağılımı

Bina Kat Adedi	Cephe Görseli Adedi
1	2
2	245
3	1030
4	1784
5	923
6	320
7	121
8	75
TOPLAM	4500

Bu tez çalışması kapsamında mukayese edilen Ön Eğitimli KSA yapıları Türkiye'deki yapı stokunun tamamını kapsayan nitelikte değildir. Bunun temel sebebi:

- Dış cephesi ile zaman içinde oynanmış (örneğin giydirme cephe vs. yapılmış) binaların varlığından dolayı uygulamada bazı binalar için bu yöntem uygulanmamıştır.
- Bununla beraber literatürdeki hızlı değerlendirme amacıyla kullanılan ve tezde bahsedilen tüm yöntemlerin az-orta katlı binalar için uygun sonuçlar verdiği bilinmektedir. Bu nedenle bu tez çalışmasında mukayese edilecek Ön Eğitimli KSA yapıları yalnızca hızlı değerlendirme yöntemlerinde dikkate alınan parametrelerden 3 tanesi için ve en fazla 8 katlı betonarme binalar için geçerli olmuştur.
- Toplumsal önceliği olan, okul, hastane, haberleşme tesisi, askeri tesis vs. gibi amaçlarla kullanılan bina türleri de yine hızlı değerlendirme yöntemlerinin kapsamı dışında olduğu için bu tez kapsamında da yer almamıştır.

Aslında bu tezin temel amacı; hızlı değerlendirme yöntemlerinde kullanılan girdi parametrelerinin elde edilmesi olduğundan ve hızlı değerlendirme yöntemlerinin yukarıda belirtilen kısıtlar içinde uygulanmasından dolayı bu şekilde bir ayırım yapılmıştır. Diğer türlü amaç sadece her bir parametrenin elde edilmesi olacak ise yukarıdaki sınırlandırmalara da ihtiyaç olmayacaktır.

Veri tabanı oluşturma ve veri ön işlem süreci: görüntü toplama (tüm erişilebilir (mevcut) olan bina ön, yan ve/veya arka cephe görüntüleri) ve görüntü etiketleme olmak üzere iki görevden oluşmaktadır. Tez çalışmasının bu kısmında, binaları yüksek hassasiyetle sınıflandırmak ve yüksek doğrulukta bir model oluşturabilmek için Google Street View Static API kullanılarak 4.500 adet bina cephe görseli toplanmıştır. Eğitim amacıyla, bina cephe görsellerinin etiketlenmesi gerekmektedir. Bu tez çalışmasında, bina cephe görselleri manuel olarak ikili sınıflandırma ve çok sınıflı sınıflandırma stratejileri kullanılmak üzere etiketlenmiştir. Bu etiketler: a) Ağır çıkma olan binalar b) Bitişik nizam (çarpışma etkisindeki) binalar c) Eğimli arazi üzerine inşa edilmiş binalar (herhangi bir binanın cephe görüntüsünün birden çok etiketi olabileceğini unutulmamalıdır) d) a, b ve c'deki gibi bir yapısal problemi olmayan binalar (Referans) şeklinde olacaktır. Şekil 5.2'de örnek bina cephe görselleri verilmiştir.



Ağır Çıkmalı Bina



Bitişik Nizam Bina



Eğimli Arazide İnşa Edilmiş Bina



Referans Bina

Şekil 5.2. Örnek bina görselleri

Bu tez çalışması kapsamında Google Street View üzerinden toplanan bina cephe görsellerinin toplanış kriterleri ve tespiti yapılan 3 parametrenin varlığı ya da yokluğu durumları aşağıda belirtilen hususlar uyarınca yapılmıştır:

- Binanın hangi cephesinden veri elde edilecek ise olabildiğince tam karşısından (çap oluşturmayacak biçimde) alınmıştır (Şekil 5.3).
- Binanın zemin katı ile bir üst katı arasında oturma alanı olarak bir artış mevcut ise (tamamen duvarlarla örülü kapalı çıkma) ağır çıkma var olarak kabul edilmiştir (Bu noktada çıkmaya ilişkin uzunluk açısından 1m veya 1,5m gibi bir kriter dikkate alınmamıştır) (Şekil 5.3).
- Balkon çıkmaları, ağır çıkma olarak dikkate alınmamıştır. Bu noktada önerilen yazılım sisteminin bu farkı ayırt etmesi için yeterince balkon çıkması ve ağır çıkma görselleri etiketlenmiştir (Şekil 5.3).
- Bitişik nizamlılık durumu için binanın dikkate alınan cephesinin her iki ucunda çok küçük bir boşluk dahi var ise bitişik nizam olmadığı, komşu bir bina ile çok küçük bir temas dahi var ise bitişik nizam kabulü yapılmıştır (Bu noktada yalnızca dikkate alınan binanın herhangi bir ucunda bitişik bir bina var ise bitişik nizam kabulü yapılmıştır) (Şekil 5.3).

- Eđer bina bitiřik nizam ise komřu binaların yaklařık bir pencere mesafesi kadar kısmı cephe gorsellerine dâhil edilerek alınmıřtır. Bu noktadaki amaç, tespiti yapılan binanın hangisi olduđunun net bir řekilde ortaya konulmasıdır (řekil 5.3).
- Eđer bina bitiřik nizam deđil ise cephe gorselleri bina uç noktalarındaki bořlukları gosterecek řekilde alınmıřtır (Bu mesafe takribi bitiřik nizam durumunda dikkate alınan bir pencere mesafesi kadardır) (řekil 5.3).
- Zemin eđim durumu, bina cephe gorselinden kolaylıkla anlařılabilecek řekilde alınmıřtır. Bu noktada binanın inřa edildiđi zeminin eđimli olması ve/veya zeminde eđim olup olmadıđı net bir řekilde tespit edilemeyip binanın incelenen cephesinin her iki ucunda kolaylıkla farkedilebilir bir yuakseklık farkı varsa eđimli arazi uzerine inřa edilmiř bina olarak kabul edilmiřtir (řekil 5.3).





Ađır ıkma Var



Ađır ıkma Yok (Balkon Konsolu)



Bitiřik Nizam Var



Bitiřik Nizam Yok



Zemin Eđim Durumu Var



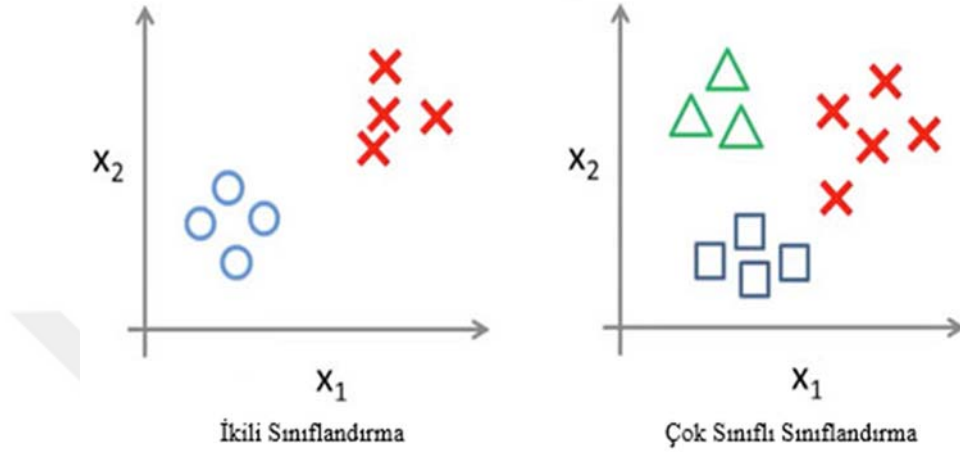
Zemin Eđim Durumu Yok

řekil 5.3. Veri setinden rnek cephe grselleri

Veri Sınıflandırması:

Veri sınıflandırması, geniş anlamda verilerin daha verimli kullanılabilmesi ve korunabilmesi için ilgili kategorilere gre dzenlenmesi sreci olarak tanımlanmaktadır. Temel dzeyde, sınıflandırma sreci verilerin bulunmasını, dzenlenmesini ve iřlenmesini kolaylařtırmaktadır. Tez alıřması kapsamında Google Street View zerinden toplanan bina cephe grselleri de bu anlamda ikili sınıflandırma ve ok sınıflı sınıflandırma stratejileri uyarınca veri tasnifi iřlemine tabi

tutulmuştur. Bu bağlamda ikili sınıflandırma ve çok sınıflı sınıflandırma mukayese edilirse ikili sınıflandırma problemlerinde sadece cevabı evet ya da hayır olan soru sorulur, eğer verilecek cevap ikiden fazla değer içinden seçilerek cevaplanacaksa buna çok sınıflı sınıflandırma problemi denilmektedir. Şekil 5.4'te ikili sınıflandırma ve çok sınıflı sınıflandırma için basit anlamda şematize bir gösterim verilmiştir.



Şekil 5.4. İkili ve çok sınıflı sınıflandırma gösterimi

İkili Sınıflandırma Stratejisi:

İkili sınıflandırma için ağır çıkma (1. veri seti), bitişik nizamlılık durumu (2. veri seti) ve eğimli arazi varlığı (3. veri seti) durumlarının varlığı ya da yokluğu için Çizelge 5.3'teki şekliyle manuel etiketleme işlemi yapılmıştır.

Çizelge 5.3. İkili sınıflandırma etiketleme çizelgesi

Parametre Türü	Var	Yok
Ağır Çıkma	✓	X
Bitişik Nizamlılık Durumu	✓	X
Eğimli Arazi Durumu	✓	X

Not: Çizelgede yer alan ✓ işareti söz konusu parametrenin var olduğunu, X işareti ise parametrenin olmadığı anlamına gelmektedir.

Çok Sınıflı Sınıflandırma Stratejisi:

Çok sınıflı sınıflandırma için ağır çıkma, bitişik nizamlılık durumu ve eğimli arazi durumlarının varlığı ya da yokluğu hallerinin kombinasyonlarını içeren 8 farklı durumu içeren bir veri seti teşkil edilmiştir (3 farklı parametre olduğu için $2^3=8$ farklı gerçekleşebilecek durum vardır). Bu veriler için tanzim edilen sınıflandırmada soldan sağa doğru ilk değer ağır çıkma, ikinci değer bitişik nizamlılık durumu, üçüncü değer ise eğimli arazi varlığıdır. Bu parametrelerden herhangi birinin var olması durumunda 1, yok olması durumunda ise 0 ile manuel etiketleme işlemi yapılmıştır. Bu durumda çok sınıflı sınıflandırma için tanzim edilen 4. veri seti içerisindeki kategorizasyonlar

Çizelge 5.4’te verilmiştir. Şekil 5.5’te ise çok sınıflı sınıflandırmaya ilişkin cephe görselleri etiket örnekleri verilmiştir.

Çizelge 5.4. Çok sınıflı sınıflandırma etiketleme çizelgesi

Ağır Çıkma	Bitişik Nizamlılık Durumu	Eğimli Arazi Durumu	Etiket Adı
X	X	X	0-0-0
X	X	✓	0-0-1
X	✓	X	0-1-0
✓	X	X	1-0-0
✓	✓	X	1-1-0
X	✓	✓	0-1-1
✓	X	✓	1-0-1
✓	✓	✓	1-1-1

Not: Çizelgede yer alan ✓ işareti söz konusu parametrenin var olduğunu, X işareti ise parametrenin olmadığı anlamına gelmektedir.





Etiket Adı:
0-0-0



Etiket Adı:
0-0-1



Etiket Adı:
0-1-0



Etiket Adı:
0-1-1



Etiket Adı:
1-0-0



Etiket Adı:
1-0-1



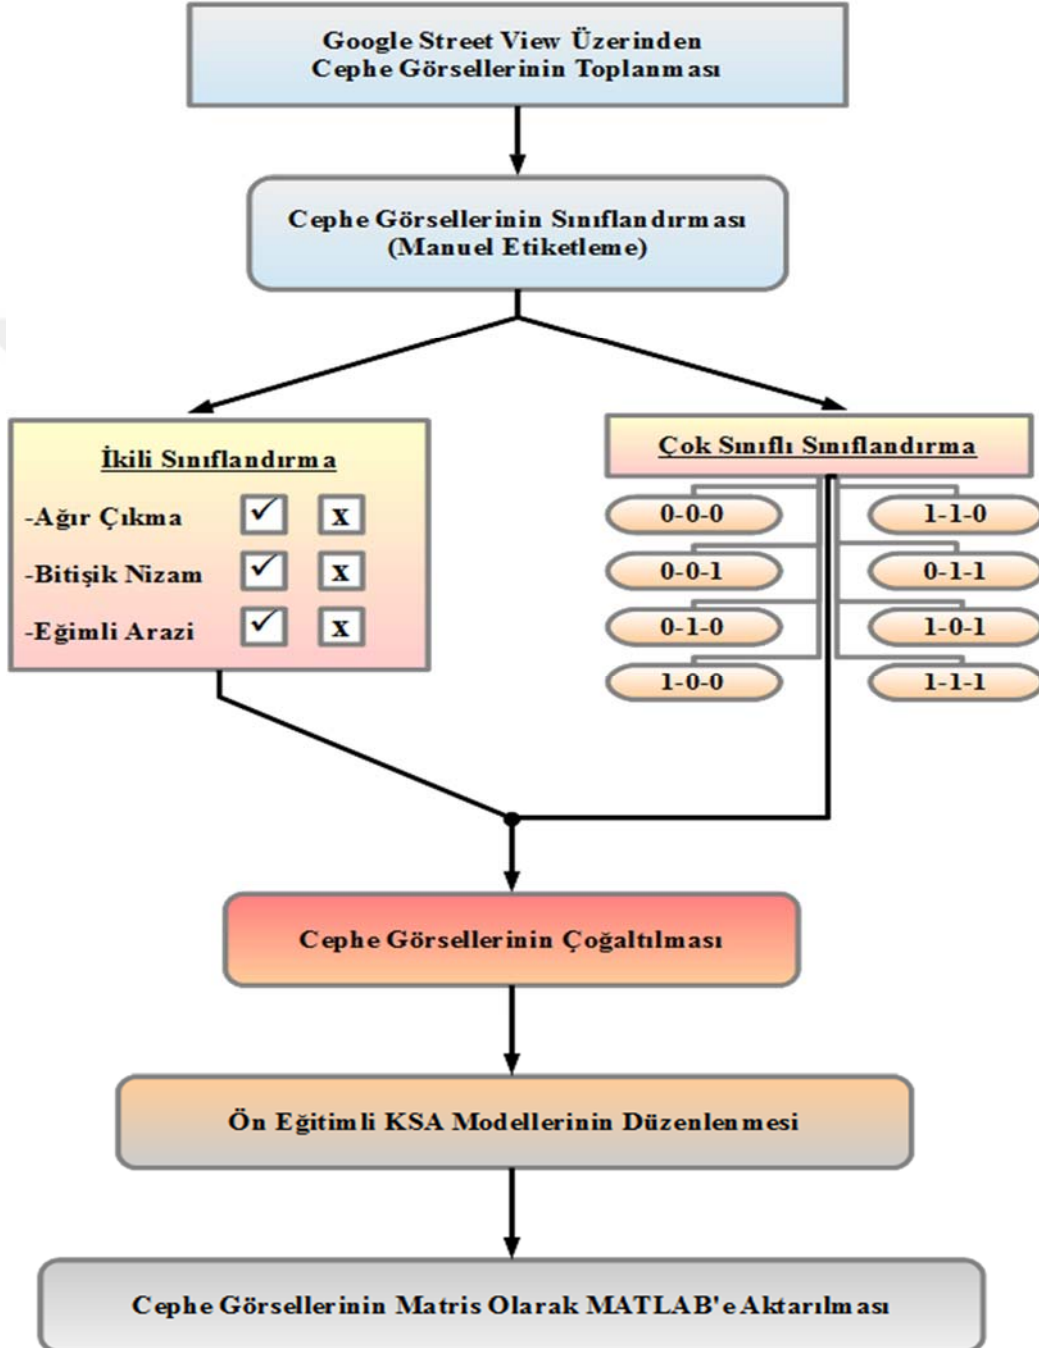
Etiket Adı:
1-1-0



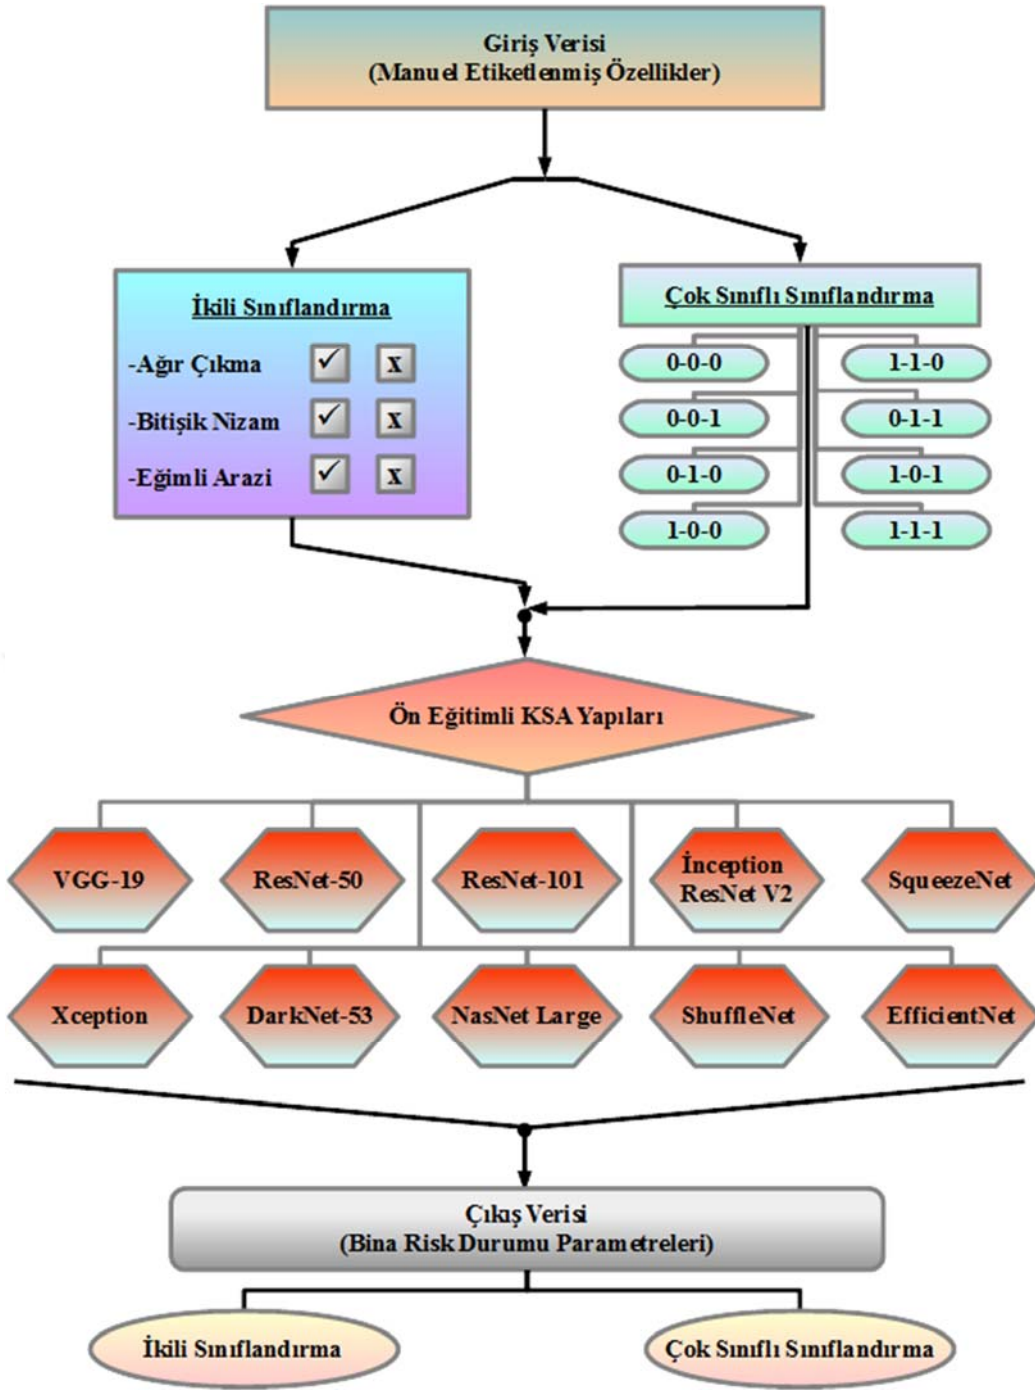
Etiket Adı:
1-1-1

Şekil 5.5. Çok sınıflı sınıflandırmaya ilişkin cephe görselleri etiket örnekleri

Şekil 5.6'da tez çalışması kapsamında görüntü işleme adımlarına ilişkin akış şeması verilmiştir. Şekil 5.7'de ise tez çalışması dâhilinde kullanılan 10 adet Ön Eğitimli KSA yapısı uyarınca ikili sınıflandırma ve çok sınıflı sınıflandırma stratejileri doğrultusunda 4 farklı veri seti ile oluşturulan giriş aşaması ve söz konusu Ön Eğitimli KSA yapılarının tahmini neticesinde bina risk durumu parametrelerinin oluşturduğu çıkış aşaması adımlarını içeren akış şeması verilmiştir.



Şekil 5.6. Veri ön işlem adımları



Şekil 5.7. Bina risk durumu parametrelerinin algoritmalar ile belirlenmesi adımları

Söz konusu CNN modeli ile Şekil 5.7’de verilen akış diyagramında da görüleceği gibi ön işleme aşamasında binanın ağır çıkma varlığı, bitişik nizamlılık durumu (ya da olası çarpışma etkisi durumu), eğimli arazi üzerine inşa edilmiş bina varlığı belirlenmiştir. Tez çalışması kapsamında ele alınan 10 adet Ön Eğitimli KSA modelinin doğrulukları “ısı haritaları (heatmap)” ile de sınanmış, algoritmaların tahmin yaparken görsellerde hangi bölgelere odaklanarak binaların bahse konu parametrelerini tahmin ettiği de belirlenmiştir. Bu kapsamda, ağır çıkma parametresinin tespitinde ısı haritalarının binanın zemin katı ile bir üst katı arasına (büyük çoğunlukla ağır çıkmanın söz konusu bölgede olduğu varsayılarak) yoğunlaşıp yoğunlaşmadığı, bitişik nizamlılık parametresinin tespitinde

binanın komşu cephelerine bakarak bu cephelerde boşluk bulunup bulunmadığı ya da komşu binaların olması durumunda söz konusu bina(lar) ile tespit yapılan binanın kesişim noktalarına yoğunlaşp yoğunlaşmadığı, eğimli arazi varlığı parametresinin tespitinde ise bina ile zeminin kesişim noktalarına yoğunlaşp yoğunlaşmadığı kontrol edilmiştir.

Diğer taraftan, Google Street View üzerinden toplanan 4500 adet bina cephe görselinin ikili sınıflandırma ve çok sınıflı sınıflandırma stratejileri için Çizelge ve Çizelge’da verilen manuel etiketleme durumlarına göre kategorize edilmesi neticesinde oluşan veri adetleri ve veri dengeleme işlemleri (mirror (aynalama), white noise (beyaz gürültü), Gaussian noise (Gauss gürültüsü)) sonucunda oluşturulan veri adetleri Çizelge 5.5. ve Çizelge 5.6’da verilmiştir. Veri dengeleme işlemi, yapılacak analizlerde sınıflandırmalar için oluşturulan kategorilerde eksik olan verilerin çoğaltılarak hesaba katılmasını sağlayarak daha tutarlı ve daha doğru sonuçlara ulaşılmasını gerçekleştirmek için icra edilmiştir.

Çizelge 5.5. İkili sınıflandırma için veri dengelemesi yapılan cephe görseli adetleri

Ağır Çıkmalı	Ağır Çıkmasız	Dengelenen Ağır Çıkmasız
2817	1327	2650
Bitişik Nizamlı	Ayrık Nizamlı	Dengelenen Bitişik Nizamlı
1015	3128	3042
Eğimli Arazide İnşa Edilmiş	Eğimsiz Arazide İnşa Edilmiş	Dengelenen Eğimli Arazide İnşa Edilmiş
593	3549	3558

Çizelge 5.6. Çok sınıflı sınıflandırma için veri dengelemesi yapılan cephe görseli adetleri


Etiket Adı	Cephe Görseli Adedi	Dengelenen Cephe Görseli Adedi
0-0-0	660	660
0-0-1	136	660
0-1-0	372	660
1-0-0	660	660
1-1-0	545	660
0-1-1	110	660
1-0-1	427	660
1-1-1	111	660

- **Aynalama (Mirror):** Herhangi bir cephe görselinin y ekseninde simetrisinin alınması neticesinde yapılan veri çoğaltma işlemidir (Şekil 5.8).



Şekil 5.8. Aynalama (mirror) işlemi ile veri çoğaltma örneği

- **White Noise (Beyaz Gürültü):** Herhangi bir cephe görselinin farklı frekanslarda eşit yoğunluğa sahip rastgele bir sinyal ve sabit bir güç spektral yoğunluğu ile çoğaltılması işlemidir (Şekil 5.9).



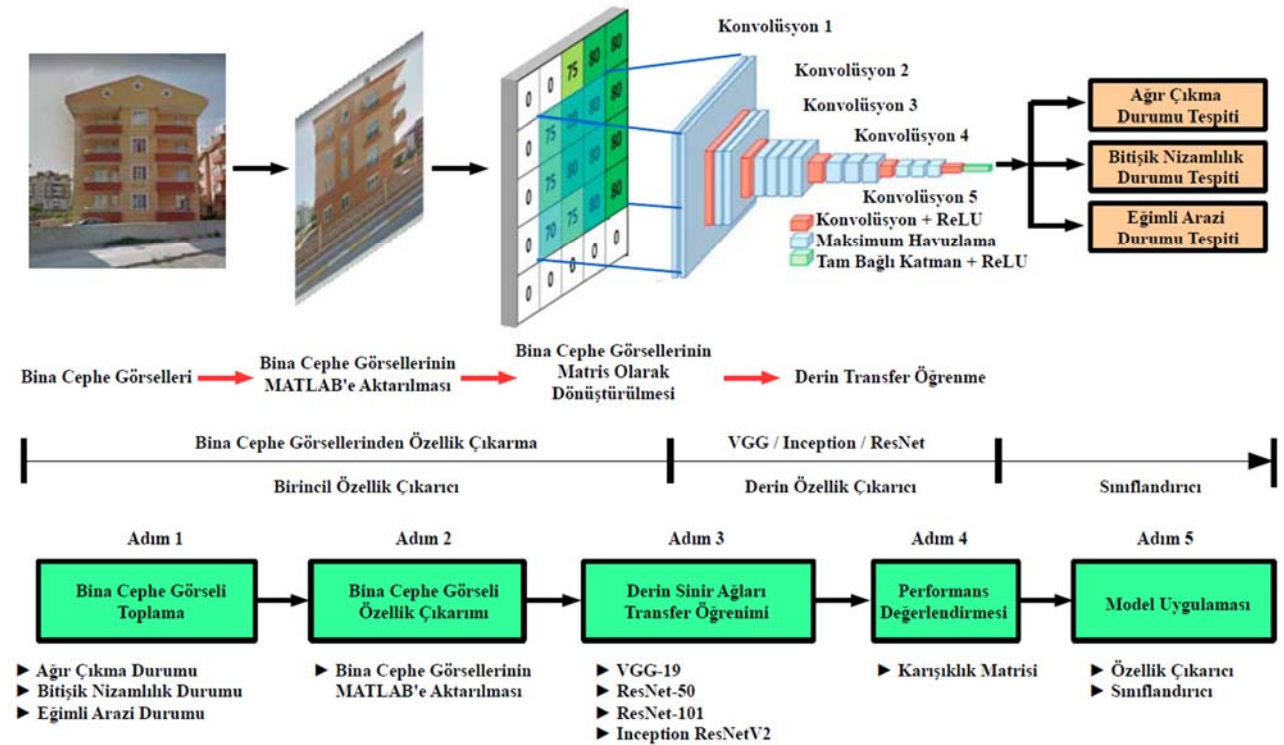
Şekil 5.9. White noise (beyaz gürültü) işlemi ile veri çoğaltma örneği

- **Gaussian Noise (Gauss Gürültüsü):** Herhangi bir cephe görselinin normal dağılımdakine eşit olasılık yoğunluk fonksiyonuna sahip bir tür sinyal gürültüsü ile çoğaltılması işlemidir (Şekil 5.10).



Şekil 5.10. Gaussian noise (Gauss gürültüsü) işlemi ile veri çoğaltma örneği

Tez kapsamında önerilen ikili sınıflandırma ve çok sınıflı sınıflandırma algoritması için Ön Eğitimli KSA yapıları olan DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50 mimarileri kullanılmıştır. Söz konusu algoritmaların ana mimarileri 4. Bölümde verilmiş olup, bu bölümde ise tez çalışmasında yapılan değişiklikler ve nasıl kullanıldıklarını içeren detaylar anlatılmıştır. Ayrıca söz konusu mimariler ile tez çalışmasının entegrasyonunu oluşturan şematik gösterim Şekil 5.11’de verilmiştir. (Söz konusu şeklin derin transfer öğrenme kısmı aynı kökenden gelen mimariler olan VGG, ResNet ve Inception için teşkil edilmiştir.)



Şekil 5.11. Ön Eğitimli KSA yapıları ile hızlı sismik değerlendirme parametrelerinin entegrasyonu şematik gösterimi

• VGG-19

VGG-19 mimarisinde girdi, sabit boyutlu 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) RGB görüntüsüdür (Ağın genişliği, gizli bir katmandaki gizli düğümlerin miktarını ifade eder. Ağın yüksekliği ise ağda bulunan gizli katmanların sayısını ifade eder). Söz konusu mimaride tek ön işleme, eğitim setinde hesaplanan ortalama RGB (RGB renk modeli bir eklemeli renk modelidir ki burada kırmızı, yeşil ve mavi ışık geniş renk yelpazesi üretmek için çeşitli şekillerde birbirine eklenir.) değerini her pikselden çıkarma ile gerçekleştirilmektedir. Görüntü, çok küçük bir alıcı alana sahip filtreler kullandığı için bir evrişimli katman yığınından geçirilir. Her bir VGG-19 mimarisi, 3×3 kernel boyutlarını kullanarak evrişimi ve evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde birer piksellik adımlarla kaydırma işlemi (stride) gerçekleştirmiştir. Konfigürasyonlardan birinde, giriş kanallarının doğrusal bir dönüşümü olarak görülebilen 1×1 evrişim filtreleri de kullanılmıştır. Evrişim katmanlarının genişliği (kanal sayısı) oldukça küçüktür, ilk katmanda 64'ten

başlar ve daha sonra 512'ye ulaşana kadar her maksimum havuzlama katmanından sonra 2 kat artarken giriş boyutu da yarı yarıya azalmaktadır. Evrişim katmanı girişinin uzamsal dolgusu, uzamsal çözünürlüğün evrişimden sonra korunacağı şekildedir, yani dolgu 3 x 3 evrişim katmanları için 1 pikseldir. Uzamsal havuzlama, bazı evrişim katmanlarını takip eden 5 maksimum havuzlama katmanı tarafından gerçekleştirilir (Tüm evrişim katmanlarını maksimum havuzlama izlemez). Farklı mimarilerde farklı bir derinliğe sahip olan bir evrişimsel katman yığını, üç Tam Bağlantılı (FC) katman izler: ilk ikisinin her biri 4096 kanala sahiptir, üçüncüsü 1000 yollu ILSVRC (ImageNet Large Scale Visual Recognition Challenge) sınıflandırması gerçekleştirir ve böylece 1000 kanal içerir (1000 sınıf). Ama bu tez çalışmasında, ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1×1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1×1 filtre boyutunda bir katman oluşturulmuştur.

- **ResNet-50/ResNet-101**

ResNet-50 ve ResNet-101 CNN mimarileri 4 aşamadan oluşmaktadır. Söz konusu ağ, 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak alır. Bu tezde ResNet-50 ve ResNet-101'i Çizelge 4.3. ve Çizelge 4.4'te göstermek için, giriş görüntüsünün 224 (yükseklik) × 224 (genişlik) × 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir ResNet mimarisi, sırasıyla 7 × 7 ve 3 × 3 kernel boyutlarını kullanarak ilk evrişimi ve maksimum havuzlamayı gerçekleştirir. Daha sonra her biri 3 katman içeren 3 artık bloğa sahip olan ağın 1. aşaması başlar. Bu üç katman 1 × 1, 3 × 3, 1 × 1 evrişimleridir. 1. aşama bloğunun 3 katmanının tamamında evrişim işlemini gerçekleştirmek için kullanılan filtrelerin boyutu sırasıyla 64, 64 ve 256'dır. 1. aşamanın son bloğunda, girdinin boyutunu; yükseklik ve genişlik açısından yarıya indirmek için bir alt örnekleme stratejisi kullanılır. Bu nedenle, bir aşamadan diğerine ilerledikçe, kanal genişliği ikiye katlanır ve giriş boyutu yarı yarıya azalır. Son olarak, ağın bir ortalama havuzlama (average pooling) katmanına ve ardından çok sınıflı sınıflandırmaya ulaşması için 1000 nörona sahip tam bağlantılı bir katman oluşturulur. Ama bu tez çalışmasında, ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1×1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1×1 filtre boyutunda bir katman oluşturulmuştur.

- **Inception ResNetV2**

Inception-ResNet V2 mimarisi ağı; 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Söz konusu mimari için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir Inception-ResNet V2 mimarisi, 3 \times 3 ve 1 \times 1 kernel boyutlarını kullanarak evrişimi ve evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde birer piksellik adımlarla kaydırma işlemi (stride) gerçekleştirmiştir.

İlgili KSA yapısında her bir konvolüsyondan sonra katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Toplu normalleştirme işlemlerini takiben de RELU aktivasyon fonksiyonu kullanılmıştır. Son olarak, ağırlık ortalaması (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısıyla ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1 \times 1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1 \times 1 filtre boyutunda bir katman oluşturulmuştur.

- **SqueezeNet**

SqueezeNet mimarisi ağı; 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Söz konusu mimari için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir SqueezeNet mimarisi, Çizelge 4.5'te belirtilen adımlar uyarınca filtre boyutu, adım değeri ve diğer parametreleri ve boyutlarını kullanarak analiz işlemi gerçekleştirilmektedir.

Bu KSA yapısında RELU aktivasyon fonksiyonu kullanılmıştır. Son olarak, ağırlık ortalaması (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısıyla ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1 \times 1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1 \times 1 filtre boyutunda bir katman oluşturulmuştur.

- **Xception**

Xception mimarisi ağı; 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Söz konusu mimari için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir Xception mimarisi, Şekil 4.23'te

belirtilen adımlar uyarınca filtre boyutu, adım değeri ve diğer parametreleri ve boyutlarını kullanarak analiz işlemini gerçekleştirmektedir.

Bu KSA yapısında her bir konvolüsyondan sonra katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Toplu normalleştirme işlemlerini takiben de RELU aktivasyon fonksiyonu kullanılmıştır. Son olarak, ağın bir ortalama havuzlama (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1×1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1×1 filtre boyutunda bir katman oluşturulmuştur.

- **ShuffleNet**

ShuffleNet mimarisi ağı; 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Söz konusu mimari için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir ShuffleNet mimarisi, Çizelge 4.6'da belirtilen adımlar uyarınca filtre boyutu, adım değeri ve diğer parametreleri ve boyutlarını kullanarak analiz işlemini gerçekleştirmektedir.

Bu KSA yapısında her bir konvolüsyondan sonra katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Toplu normalleştirme işlemlerini takiben de RELU aktivasyon fonksiyonu kullanılmıştır. Söz konusu aktivasyon fonksiyonundan sonra da kanal karıştırma işlemi icra edilmektedir. Son olarak, ağın bir ortalama havuzlama (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1×1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1×1 filtre boyutunda bir katman oluşturulmuştur.

- **DarkNet-53**

Bu KSA yapısında her bir konvolüsyondan sonra katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Her 2 konvolüsyon işleminden sonra da additional layer oluşturulmuştur. Bahse konu Ön Eğitimli KSA yapısında Leaky RELU aktivasyon fonksiyonu kullanılmıştır. Ayrıca, söz konusu ağı; 32 ve 3'ün

katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Bu tezde DarkNet-53 için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir DarkNet mimarisi, sırasıyla 3 \times 3 ve 1 \times 1 kernel boyutlarını kullanarak ilk evrişimi ve evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde ikişer piksellik adımlarla kaydırma işlemi (stride) gerçekleştirmiştir. Evrişim işlemi gerçekleştirilmek için kullanılan filtrelerin boyutu sırasıyla 32, 64, 128, 256 ve 32'nin katları olacak şekilde 1024'e kadar erişmiştir. 1. konvolüsyonda filtre boyutu 32 ile başlamış 52. konvolüsyonda söz konusu filtre boyutu 1024'e erişmiş ve son konvolüsyon olan 53. konvolüsyonda filtre boyutu 2'ye düşmüştür. Son olarak, 23. additional layer'dan sonra ağda bir global ortalama havuzlama (global average pooling) (Özellik haritalarının üzerine CNN yapılarında kullanılan tamamen bağılı katmanlar eklemek yerine her bir özellik haritasının ortalamasını alan ve ortaya çıkan vektörün doğrudan softmax aktivasyon fonksiyonunu beslediği havuzlama yöntemi) katmanı ve ardından son konvolüsyon işlemi gerçekleştirilerek ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1 \times 1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1 \times 1 filtre boyutunda bir katman oluşturulmuştur.

- **NasNet Large**

NasNet Large mimarisi için giriş görüntüsünün 331 (yükseklik) \times 331 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir NasNet Large mimarisi, Bölüm 4.3.8'de belirtilen adımlar uyarınca filtre boyutu, adım değeri, genişletilmiş evrişim işlemi, derinlemesine ayrılabilir evrişim işlemi ve diğer parametreleri ve boyutlarını kullanarak analiz işlemini gerçekleştirmektedir.

Bu KSA yapısında her bir konvolüsyondan sonra katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Toplu normalleştirme işlemlerini takiben de RELU aktivasyon fonksiyonu kullanılmıştır. Son olarak, ağın bir ortalama havuzlama (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkış katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1 \times 1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1 \times 1 filtre boyutunda bir katman oluşturulmuştur.

- **EfficientNet**

Bu tez çalışması kapsamında EfficientNet B0 üzerinde eğitilmiş 290 katmandan (layer) oluşan ve yaklaşık 4 milyon nöronu bünyesinde barındıran bir Ön Eğitimli KSA yapısı kullanılmıştır. Bu KSA yapısında 65 adet konvolüsyon ve 16 adet grup konvolüsyon işlemi gerçekleştirilmiştir. Katmanların girdilerini yeniden merkezleme ve yeniden ölçeklendirerek normalleştirme yoluyla YSA'yı daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntem olan batch normalization (toplu normalleştirme) işlemi gerçekleştirilmiştir. Ayrıca, addition layer ve eleman bazlı matris çarpım (element-wise multiplication) işlemleri de icra edilmiştir. Bahse konu Ön Eğitimli KSA yapısında Sigmoid aktivasyon fonksiyonu kullanılmıştır. Ayrıca, söz konusu ağ; 32 ve 3'ün katları olarak yüksekliği ve genişliği olan giriş görüntüsünü kanal genişliği olarak almıştır. Bu tezde EfficientNet B0 için giriş görüntüsünün 224 (yükseklik) \times 224 (genişlik) \times 3 (kanal) boyutunda olduğu düşünülmüştür. Her bir EfficientNet B0 mimarisi, 3 \times 3 ve 1 \times 1 kernel boyutlarını kullanarak evrişimi ve evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde birer ve ikişer piksellik adımlarla kaydırma işlemi (stride) gerçekleştirmiştir. Grup konvolüsyon işlemlerinde 5 \times 5 filtre boyutları kullanılmıştır.

Bu KSA yapısında son olarak, ağın bir ortalama havuzlama (average pooling) katmanına ve ardından ikili sınıflandırmaya ulaşmak için son katmanda (çıkı katmanı), softmax aktivasyon işlevi aracılığıyla ikili çapraz entropi kaybı işlevi, çok sınıflı sınıflandırmaya ulaşmak için de son katmanda (çıkı katmanı), softmax aktivasyon işlevi aracılığıyla çoklu çapraz entropi kaybı işlevi kullanılmıştır. Dolayısı ile ikili sınıflandırmada son konvolüsyon işleminde 2 nörona sahip 1 \times 1 filtre boyutunda, çok sınıflı sınıflandırmada ise 8 nörona sahip 1 \times 1 filtre boyutunda bir katman oluşturulmuştur.

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez kapsamında oluşturulan 4 farklı veri seti için ikili sınıflandırma ve çok sınıflı sınıflandırma stratejileri uygulanmak suretiyle son yıllarda sıklıkla tercih edilen, açık kaynak kodlu programlama dillerinden MATLAB programı vasıtasıyla 10 adet Ön Eğitimli KSA (DarkNet-53, EfficientNet, Inception ResNetV2, NasNet Large, ResNet-101, ShuffleNet, SqueezeNet, VGG-19, Xception, ResNet-50) çalışma özelinde bazı katmanlarında düzenlemeler yapılarak analize tabi tutulmuş ve analiz sonuçları bu bölümde karşılaştırmalı olarak açıklanmıştır.

Ağır çıkma varlığının tespiti için teşkil edilen 1. veri setinde Google Street View üzerinden toplanan cephe görselleri veri dengeleme işlemlerine tabi tutulmak suretiyle çoğaltılmış ve 5467 adet cephe görseli söz konusu analiz için kullanılmıştır. Sırasıyla benzer işlemler yapılarak oluşturulan 2. (bitişik nizamlılık durumu), 3. (eğimli arazi varlığı), 4. (çok sınıflı sınıflandırma) veri setlerinde 6170, 7107 ve 5280 adet cephe görseli kullanılmıştır.

Derin sinir ağları, veriler üzerinden öğrenme işlemini gerçekleştirip ardından farklı veriler üzerinden tahmin yapabilen algoritmalarıdır. Bu nedenle her bir veri seti için yapılan analizlerde söz konusu cephe görsellerinin %80'i eğitim, %20'si de test işlemleri için kullanılmıştır. Her bir veri seti için bahsi geçen 10 adet Ön Eğitimli KSA yapısı ile analiz yapılmış olup toplam 40 adet analiz sonucu elde edilmiştir.

Yapılan analizlerde eğitimin optimum bir biçimde gerçekleşmesi tüm verilerin ağı yalnızca bir kez değil “döngü (epoch)” parametresi için girilen sayı değeri kadar tekrarlanması vasıtasıyla sağlanır. Bu değer gereğinden daha küçük belirlenmesi başarılı bir model elde edilememesine, gereğinden büyük seçilmesi ise ezberleme durumunun ortaya çıkmasına sebebiyet verebilmektedir. Analizler oluşturulurken farklı çalışmalarda kullanılan değerler incelenmiş ve epoch değeri 100 olarak belirlenmiştir (Analiz süresinin çok zaman alması nedeniyle devir sayısı 3. veri seti için yapılan NasNet Large analizinde 10, 4. veri seti için yapılan NasNet Large analizinde ise 20 olarak alınmıştır).

Bir ağı parametrelerinin ne kadar hızlı güncellendiğini gösteren öğrenme hızı (learning rate) ise genellikle 10^{-1} ile 10^{-6} değerleri arasından seçilmektedir. Yapılan çalışmalarda en iyi sonucu almak amacıyla 0,1 değerinden başlanıp alınan sonuca göre öğrenme hızı küçültülmektedir. Tez çalışması kapsamında yapılan analizlerde bu değer 0,0003 olarak dikkate alınmıştır.

Analizlerde kullanılacak olan veri sayısının çok fazla olması hem zaman hem de bilgisayar performansı açısından problem oluşturabilmektedir. Bu nedenle toplanan veriler belirli sayılarda gruplara ayrılmaktadır. Grup sayısını belirleyen “yığın boyutu (batch size)” parametresi genellikle 2'nin katları olacak şekilde 2, 4, 6, 8, 16, 32,..512 sayıları arasından seçilebilmektedir. Analizlerin yapıldığı bilgisayarda bellekle ilgili yeterli kapasite olmadığından bu noktada yığın boyutu maksimum 32 alınabilmektedir.

Doğrusal verileri doğrusal olmayan verilere dönüştürerek ağı kavrama yeteneğini artıran aktivasyon fonksiyonları evrişimli katmanlarda ve sınıflandırma katmanında kullanılmaktadır. Daha önce yapılmış çalışmalarda kullanılan ve başarılı sonuçlar elde edilen ReLU aktivasyon fonksiyonu evrişimli katmanlarda kullanılmıştır. Sınıflandırma problemlerini başarıyla gerçekleştiren Softmax aktivasyon fonksiyonu ise sınıflandırma katmanında kullanılması için tercih edilmiştir.

Tez kapsamında icra edilen 40 analiz için yapılan tahminlerdeki hata oranını belirlemek için “kayıp (loss)” fonksiyonlarından oluşturulan söz konusu Ön Eğitimli KSA yapılarına en uygun olduğu düşünülen çapraz entropi (cross entropy) seçilmiştir. Bahse konu hata oranını minimuma indirmek için her epochta ağı güncelleyen optimizasyon fonksiyonlarından başarısı kanıtlanmış SGDM (Stokastik Gradyan İniş) tercih edilmiştir.

Söz konusu analizlerin her bir döngüsü tamamlandığında elde edilen hata ve doğruluk oranlarını görüp bu değerleri yorumlamak amacıyla “metric” parametrelerinden “doğruluk (accuracy)” kullanılmıştır.

Diğer taraftan, yapılan analizlerde söz konusu Ön Eğitimli KSA mimarilerinin ezberleme durumunu ortadan kaldırmak amacıyla yapılan işlemlerden bir tanesi de veri artırmadır. Çalışmada hâlihazırda aynalama ve gürültü işlemleri ile veri artırma işlemi yapıldığından ezberlemenin önüne geçmek için seyreltme (dropout) katmanının eklenmesine karar verilmiştir. Söz konusu katman ardışık tüm Ön Eğitimli KSA mimarilerinde sınıflandırma katmanından hemen önce konumlandırılmaktadır. Yapılan çalışmalarda seyreltme katmanında belirlenen eşik değeri genellikle 0,5'tir. Bu doğrultuda bahse konu değeri 0,5 alınmış ve bu değerin altında kalan nöronlar devre dışı bırakılarak mimarilerin ezberleme durumu engellenmiştir.

Analizlerde kullanılan parametre değerleri Çizelge 6.1'de verilmiştir.

Çizelge 6.1. Analizlerde kullanılan parametre değerleri	
Parametre Türü	Parametre Değeri
Giriş Görüntü Boyutu	224×224×3*
Yığın Boyutu (Batch Size)	32 (Maksimum)
Devir (Epoch)	100*
Optimizasyon Fonksiyonu	SGDM
Metrik (Metrics)	Doğruluk (Accuracy)
Aktivasyon Fonksiyonları	ReLU, Softmax
Kayıp (Loss) Fonksiyonu	Çapraz Entropi
Seyreltme (Dropout) Değeri	0,5
Öğrenme Oranı (Learning Rate)	0,0003

Not 1: Analiz süresinin çok zaman alması nedeniyle devir sayısı 3. veri seti için yapılan NasNet Large analizinde 10, 4. veri seti için yapılan NasNet Large analizinde ise 20 olarak alınmıştır.

Not 2: Giriş görüntü boyutu yalnızca NasNet Large analizlerinde 331×331×3 olarak alınmıştır.

Not 3: Analizlerde dikkate alınan iterasyon sayılarının farklı olması söz konusu mimarilerin yapılan araştırmalar neticesinde optimum doğruluk yüzdelerine erişmesini sağlayan iterasyon değerleri olmasından kaynaklanmaktadır.


Ayrıca bahsi geçen tüm analizler; 11. nesil Intel(R) Core (TM) i7-11800H @ 2.30 GHz işlemcisi, 16 GB RAM'i ve Nvidia GeForce RTX 3060 ekran kartı olan bir bilgisayarda yapılmıştır.

1. veri seti için kullanılan Ön Eğitimli KSA mimarilerinin, manuel olarak etiketleme işlemi ile belirlenen parametre sınıfları için yaptığı tahminler neticesinde elde ettiği doğruluk yüzdeleri (doğruluk yüzdesi; doğru sınıflandırılmış bina cephe görseli sayısının tüm bina cephe görseli sayısına oranını ifade etmektedir), her bir devirde (epoch) yapmış olduğu iterasyon sayıları ve analiz süreleri karşılaştırmalı olarak Çizelge 6.2'de verilmiştir. Şekil 6.1'de söz konusu Ön Eğitimli KSA mimarilerinin 1. veri seti (ağır çıkma) için doğruluk yüzdelerini içeren grafik, Şekil 6.2'de de analiz sürelerini gösteren grafik verilmiştir. Ayrıca 1. veri seti içinde yer alan her bir mimari için iterasyona bağlı doğruluk ve kayıp değişimi grafikleri sırasıyla Şekil 6.3-Şekil 6.22'de verilmiştir.


Diğer taraftan, MATLAB programında yapılan analizler neticesinde Ön Eğitimli KSA mimarilerinin doğruluk yüzdelerini tespit ederken cephe görselleri üzerinde yoğunlaştığı bölgeleri içeren ısı haritalı (heatmap) görseller de Şekil 6.23'te verilmiştir.

Çizelge 6.2. 1. veri seti (ağır çıkma varlığı) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları

Ön Eğitimli KSA Türü	Doğruluk Yüzdesi	İterasyon Sayısı	Analiz Süresi (Dakika)
VGG-19	87,01	589	330
ResNet-50	88,20	589	356
ResNet-101	84,30	147	319
Inception ResNetV2	80,56	294	967
SqueezeNet	85,40	147	102
Xception	84,80	147	240
ShuffleNet	82,51	147	137
DarkNet-53	88,62	294	328
NasNet Large	87,86	1178	9868
EfficientNet	85,31	294	489




Şekil 6.1. 1. veri seti (ağır çıkma varlığı) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları




Şekil 6.2. 1. veri seti (ağır çıkma varlığı) için Ön Eğitimli KSA mimarilerinin analiz süreleri mukayesesi


Not: Analiz süreleri için verilen grafiğin anlamlı bir hal alması ve söz konusu Ön Eğitimli KSA modellerinin mukayese edilebilirliğinin daha anlaşılır olması için NasNet Large mimarisinin analiz süresi grafikte %10 mertebesinde verilmiştir.



Şekil 6.3. İkili sınıflandırma (VGG-19) iterasyona bağlı doğruluk değişimi




Şekil 6.4. İkili sınıflandırma (VGG-19) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 - -●- - Doğrulama

Şekil 6.5. İkili sınıflandırma (ResNet-50) iterasyona bağlı doğruluk değişimi

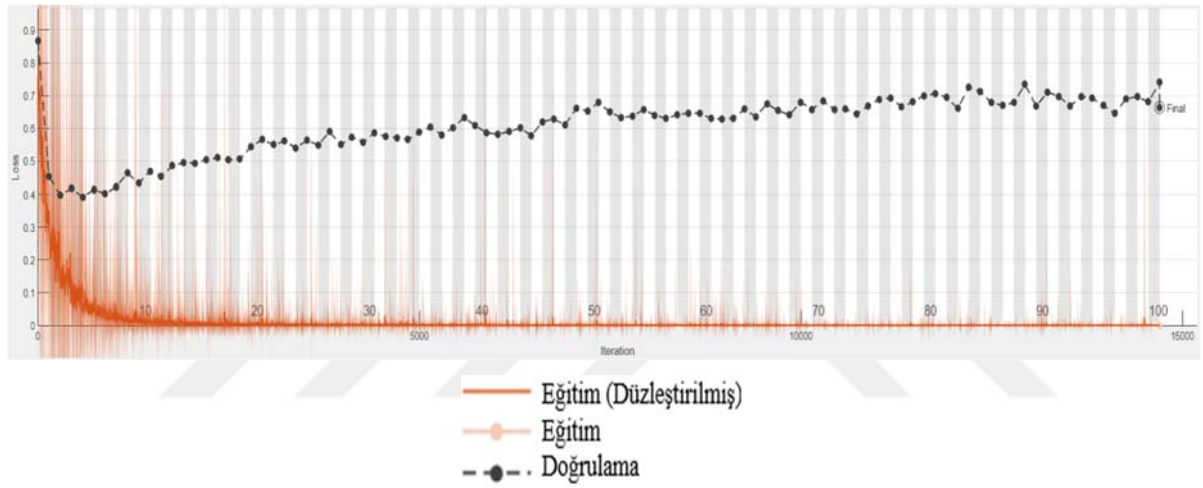


— Eğitim (Düzeltilmiş)
 —●— Eğitim
 - -●- - Doğrulama


Şekil 6.6. İkili sınıflandırma (ResNet-50) iterasyona bağlı kayıp değişimi



Şekil 6.7. İkili sınıflandırma (ResNet-101) iterasyona bağlı doğruluk değişimi




Şekil 6.8. İkili sınıflandırma (ResNet-101) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.9. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.10. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.11. İkili sınıflandırma (SqueezeNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.12. İkili sınıflandırma (SqueezeNet) iterasyona bağlı kayıp değişimi



Şekil 6.13. İkili sınıflandırma (Xception) iterasyona bağlı doğruluk değişimi




Şekil 6.14. İkili sınıflandırma (Xception) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.15. İkili sınıflandırma (ShuffleNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.16. İkili sınıflandırma (ShuffleNet) iterasyona bağlı kayıp değişimi



Şekil 6.17. İkili sınıflandırma (DarkNet-53) iterasyona bağlı doğruluk değişimi




Şekil 6.18. İkili sınıflandırma (DarkNet-53) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.19. İkili sınıflandırma (NasNet Large) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.20. İkili sınıflandırma (NasNet Large) iterasyona bağlı kayıp değişimi



— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.21. İkili sınıflandırma (EfficientNet) iterasyona bağlı doğruluk değişimi



— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.22. İkili sınıflandırma (EfficientNet) iterasyona bağlı kayıp değişimi




Manuel Etiketlenen Cephe Görsele



Ön Eğitilmiş KSA Kararı



Manuel Etiketlenen Cephe Görsele



Ön Eğitilmiş KSA Kararı



Manuel Etiketlenen Cephe Görsele



Ön Eğitilmiş KSA Kararı

Şekil 6.23. 1. veri seti (ağır çıkma varlığı) için Ön Eğitilmiş KSA mimarilerinin ısı haritası örnekleri

Çizelge 6.1’de gösterildiği gibi, Google Street View üzerinden elde edilen bina cephe görsellerinin manuel olarak etiketlenmesi neticesinde oluşturulan 1. veri seti (ağır çıkma varlığı) için tez çalışması kapsamında kullanılan Ön Eğitilmiş KSA modelleri vasıtasıyla ağır çıkma varlığı durumu yüksek doğruluk oranı ile tespit edilmiştir. Ayrıca, elde edilen doğruluk oranlarının yanı sıra ısı haritalarının (Şekil 6.23) binanın zemin katı ile bir üst katı arasına (büyük çoğunlukla ağır çıkmanın söz konusu bölgede olduğu varsayılarak) yoğunlaşmış ve bu noktada da başarılı sonuçlar elde edilmiştir. Kullanılan Ön Eğitilmiş KSA modelleri ile 1. veri seti için

en yüksek doğruluk oranı DarkNet-53 mimarisi yardımıyla %88,62 olarak elde edilmiş iken en düşük doğruluk oranı da Inception ResNetV2 mimarisi yardımıyla %80,56 olarak belirlenmiştir. Çizelge 6.1'deki doğruluk yüzdeleri incelendiğinde yaklaşık %8'lik bir spektrumda doğruluk yüzdesi farklılığı olduğu görülmektedir.


Diğer taraftan, söz konusu Ön Eğitimli KSA modelleri ile yapılan hesaplamalar dâhilinde analiz süreleri mukayase edildiğinde Xception mimarisi 102 dakika ile en kısa sürede eğitim işlemini tamamlarken, NasNet Large mimarisi 9868 dakika ile en uzun sürede eğitim işlemini tamamlamıştır.

2. veri seti için kullanılan Ön Eğitimli KSA mimarilerinin, manuel olarak etiketleme işlemi ile belirlenen parametre sınıfları için yaptığı tahminler neticesinde elde ettiği doğruluk yüzdeleri her bir devirde (epoch) yapmış olduğu iterasyon sayıları ve analiz süreleri karşılaştırmalı olarak Çizelge 6.3'te verilmiştir. Şekil 6.24'te söz konusu Ön Eğitimli KSA mimarilerinin 2. veri seti (bitişik nizam) için doğruluk yüzdelerini içeren grafik, Şekil 6.25'te de analiz sürelerini gösteren grafik verilmiştir. Ayrıca 2. veri seti içinde yer alan her bir mimari için iterasyona bağlı doğruluk ve kayıp değişimi grafikleri sırasıyla Şekil 6.26-Şekil 6.45'te verilmiştir.


Diğer taraftan, MATLAB programında yapılan analizler neticesinde Ön Eğitimli KSA mimarilerinin doğruluk yüzdelerini tespit ederken cephe görselleri üzerinde yoğunlaştığı bölgeleri içeren ısı haritalı (heatmap) görseller de Şekil 6.46'da verilmiştir.

Çizelge 6.3. 2. veri seti (bitişik nizamlılık durumu) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları

Ön Eğitimli KSA Türü	Doğruluk Yüzdesi	İterasyon Sayısı	Analiz Süresi (Dakika)
VGG-19	95,79	557	331
ResNet-50	96,42	557	342
ResNet-101	95,16	139	303
Inception ResNetV2	91,49	278	944
SqueezeNet	94,98	139	97
Xception	94,00	139	225
ShuffleNet	91,40	139	129
DarkNet-53	96,68	278	343
NasNet Large	95,16	1115	9334
EfficientNet	94,00	278	476




Şekil 6.24. 2. veri seti (bitişik nizamlılık durumu) için Ön Eğitilmiş KSA mimarilerinin karşılaştırmalı sonuçları




Şekil 6.25. 2. veri seti (bitişik nizamlılık durumu) için Ön Eğitilmiş KSA mimarilerinin analiz süreleri mukayesesi

Not: Analiz süreleri için verilen grafiğin anlamlı bir hal alması ve söz konusu Ön Eğitilmiş KSA modellerinin mukayese edilebilirliğinin daha anlaşılır olması için NasNet Large mimarisinin analiz süresi grafikte %10 mertebesinde verilmiştir.




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.26. İkili sınıflandırma (VGG-19) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.27. İkili sınıflandırma (VGG-19) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 -●- Eğitim
 -●- Doğrulama

Şekil 6.28. İkili sınıflandırma (ResNet-50) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 -●- Eğitim
 -●- Doğrulama

Şekil 6.29. İkili sınıflandırma (ResNet-50) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.30. İkili sınıflandırma (ResNet-101) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.31. İkili sınıflandırma (ResNet-101) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.32. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.33. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.34. İkili sınıflandırma (SqueezeNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.35. İkili sınıflandırma (SqueezeNet) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.36. İkili sınıflandırma (Xception) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.37. İkili sınıflandırma (Xception) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.38. İkili sınıflandırma (ShuffleNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.39. İkili sınıflandırma (ShuffleNet) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.40. İkili sınıflandırma (DarkNet-53) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.41. İkili sınıflandırma (DarkNet-53) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.42. İkili sınıflandırma (NasNet Large) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.43. İkili sınıflandırma (NasNet Large) iterasyona bağlı kayıp değişimi



Şekil 6.44. İkili sınıflandırma (EfficientNet) iterasyona bağlı doğruluk değişimi



Şekil 6.45. İkili sınıflandırma (EfficientNet) iterasyona bağlı kayıp değişimi



Manuel Etiketlenen Cephe Görselfi



Ön Eğitimli KSA Kararı



Manuel Etiketlenen Cephe Görselfi



Ön Eğitimli KSA Kararı



Manuel Etiketlenen Cephe Görselfi



Ön Eğitimli KSA Kararı

Şekil 6.46. 2. veri seti (bitişik nizamlılık durumu) için Ön Eğitimli KSA mimarilerinin ısı haritası örnekleri

Çizelge 6.2’de gösterildiği gibi, Google Street View üzerinden elde edilen bina cephe görsellerinin manuel olarak etiketlenmesi neticesinde oluşturulan 2. veri seti (bitişik nizamlılık durumu) için tez çalışması kapsamında kullanılan Ön Eğitimli KSA modelleri vasıtasıyla bitişik nizamlılık durumu yüksek doğruluk oranı ile tespit edilmiştir. Ayrıca, elde edilen doğruluk oranlarının yanı sıra ısı haritalarının (Şekil 6.46) incelenen binanın yan cephelerinin boş olması durumunda boşluklara, komşu binaların olması durumunda ise söz konusu bina(lar) ile tespit yapılan binanın kesişim noktalarına yoğunlaşmış ve yoğunlaşmadığı da sınanmış ve bu noktada da başarılı

sonuçlar elde edilmiştir. Kullanılan Ön Eğitimli KSA modelleri ile 2. veri seti için en yüksek doğruluk oranı DarkNet-53 mimarisi yardımıyla %96,68 olarak elde edilmiş iken en düşük doğruluk oranı da ShuffleNet mimarisi yardımıyla %91,40 olarak belirlenmiştir. Çizelge 6.2’deki doğruluk yüzdeleri incelendiğinde yaklaşık %5’lik bir spektrumda doğruluk yüzdesi farklılığı olduğu görülmektedir.


Diğer taraftan, söz konusu Ön Eğitimli KSA modelleri ile yapılan hesaplamalar dâhilinde analiz süreleri mukayase edildiğinde SqueezeNet mimarisi 97 dakika ile en kısa sürede eğitim işlemini tamamlarken, NasNet Large mimarisi 9334 dakika ile en uzun sürede eğitim işlemini tamamlamıştır.

3. veri seti için kullanılan Ön Eğitimli KSA mimarilerinin, manuel olarak etiketleme işlemi ile belirlenen parametre sınıfları için yaptığı tahminler neticesinde elde ettiği doğruluk yüzdeleri, her bir devirde (epoch) yapmış olduğu iterasyon sayıları ve analiz süreleri karşılaştırmalı olarak Çizelge 6.4’te verilmiştir. Şekil 6.47’de söz konusu Ön Eğitimli KSA mimarilerinin 3. veri seti (eğimli arazi) için doğruluk yüzdelerini içeren grafik, Şekil 6.48’de de analiz sürelerini gösteren grafik verilmiştir. Ayrıca 3. veri seti içinde yer alan her bir mimari için iterasyona bağlı doğruluk ve kayıp değişimi grafikleri sırasıyla Şekil 6.49-Şekil 6.68’de verilmiştir.


Diğer taraftan, MATLAB programında yapılan analizler neticesinde Ön Eğitimli KSA mimarilerinin doğruluk yüzdelerini tespit ederken cephe görselleri üzerinde yoğunlaştığı bölgeleri içeren ısı haritalı (heatmap) görseller de Şekil 6.69’da verilmiştir.

Çizelge 6.4. 3. veri seti (eğimli arazi varlığı) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları

Ön Eğitimli KSA Türü	Doğruluk Yüzdesi	İterasyon Sayısı	Analiz Süresi (Dakika)
VGG-19	91,04	574	323
ResNet-50	93,06	663	414
ResNet-101	91,22	143	311
Inception ResNetV2	88,43	287	976
SqueezeNet	91,48	143	102
Xception	90,00	143	236
ShuffleNet	89,83	143	135
DarkNet-53	91,83	287	305
NasNet Large	86,35	2841	10212
EfficientNet	90,43	287	478




Şekil 6.47. 3. veri seti (eğimli arazi varlığı) için Ön Eğitilmiş KSA mimarilerinin karşılaştırmalı sonuçları




Şekil 6.48. 3. veri seti (bitişik nizamlılık durumu) için Ön Eğitilmiş KSA mimarilerinin analiz süreleri mukayesesi

Not: NasNet Large mimarisinin devir (epoch) sayısının 10 olarak hesaplarda dikkate alındığı unutulmamalıdır.




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.49. İkili sınıflandırma (VGG-19) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.50. İkili sınıflandırma (VGG-19) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.51. İkili sınıflandırma (ResNet-50) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.52. İkili sınıflandırma (ResNet-50) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.53. İkili sınıflandırma (ResNet-101) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.54. İkili sınıflandırma (ResNet-101) iterasyona bağlı kayıp değişimi



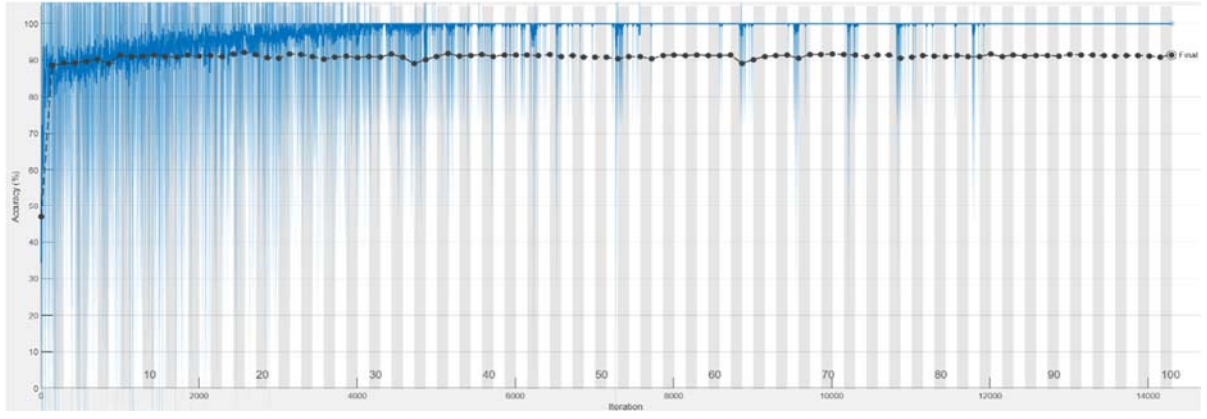
— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.55. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.56. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.57. İkili sınıflandırma (SqueezeNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

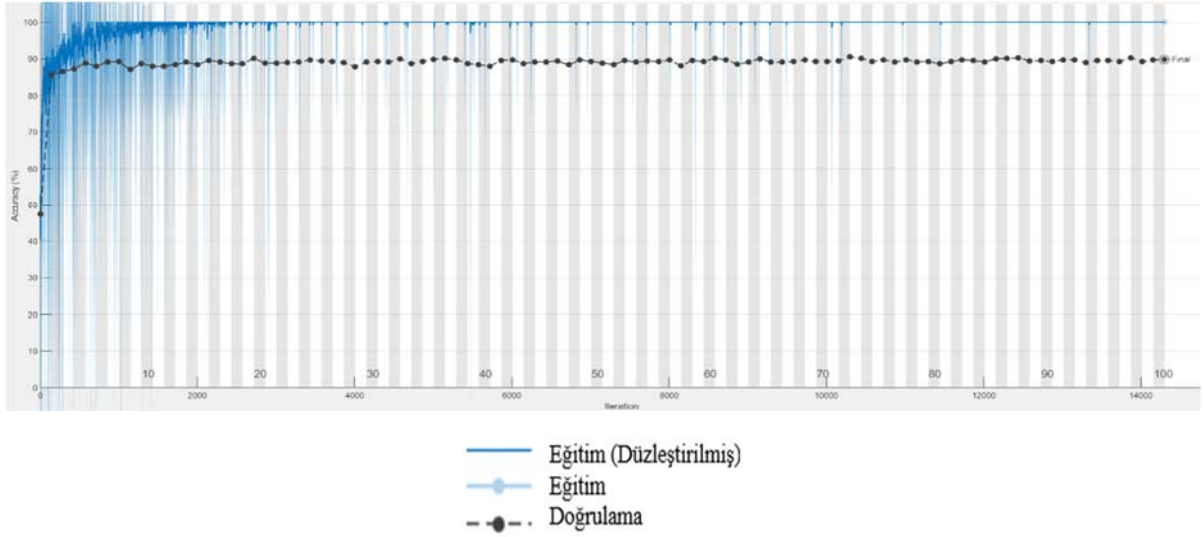
Şekil 6.58. İkili sınıflandırma (SqueezeNet) iterasyona bağlı kayıp değişimi




Şekil 6.59. İkili sınıflandırma (Xception) iterasyona bağlı doğruluk değişimi




Şekil 6.60. İkili sınıflandırma (Xception) iterasyona bağlı kayıp değişimi



Şekil 6.61. İkili sınıflandırma (ShuffleNet) iterasyona bağlı doğruluk değişimi




Şekil 6.62. İkili sınıflandırma (ShuffleNet) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.63. İkili sınıflandırma (DarkNet-53) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.64. İkili sınıflandırma (DarkNet-53) iterasyona bağlı kayıp değişimi



Şekil 6.65. İkili sınıflandırma (NasNet Large) iterasyona bağlı doğruluk değişimi




Şekil 6.66. İkili sınıflandırma (NasNet Large) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 - - Eğitim
 - - ● - Doğrulama

Şekil 6.67. İkili sınıflandırma (EfficientNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 - - Eğitim
 - - ● - Doğrulama

Şekil 6.68. İkili sınıflandırma (EfficientNet) iterasyona bağlı kayıp değişimi




Manuel Etiketlenen Cephe Görselfi



Ön Eğitilmiş KSA Kararı



Manuel Etiketlenen Cephe Görselfi



Ön Eğitilmiş KSA Kararı



Manuel Etiketlenen Cephe Görselfi



Ön Eğitilmiş KSA Kararı

Şekil 6.69. 3. veri seti (eğimli arazi varlığı) için Ön Eğitilmiş KSA mimarilerinin ısı haritası örnekleri

Çizelge 6.3'te gösterildiği gibi, Google Street View üzerinden elde edilen bina cephe görsellerinin manuel olarak etiketlenmesi neticesinde oluşturulan 3. veri seti (eğimli arazi varlığı) için tez çalışması kapsamında kullanılan Ön Eğitilmiş KSA modelleri vasıtasıyla eğimli arazi varlığı durumu yüksek doğruluk oranı ile tespit edilmiştir. Ayrıca, elde edilen doğruluk oranlarının yanı sıra ısı haritalarının (Şekil 6.69) bina ile zeminin kesişim noktalarına yoğunlaşmış ve yoğunlaşmadığı da sınanmış ve bu noktada da başarılı sonuçlar elde edilmiştir. Kullanılan Ön Eğitilmiş KSA modelleri ile 3. veri seti için en yüksek doğruluk oranı ResNet-50 mimarisi yardımıyla %93,06 olarak elde

edilmiş iken en düşük doğruluk oranı da NasNet Large mimarisi yardımıyla %86,35 olarak belirlenmiştir. Çizelge 6.3'teki doğruluk yüzdeleri incelendiğinde yaklaşık %5'lik bir spektrumda doğruluk yüzdesi farklılığı olduğu görülmektedir.


Diğer taraftan, söz konusu Ön Eğitimli KSA modelleri ile yapılan hesaplamalar dâhilinde analiz süreleri mukayese edildiğinde SqueezeNet mimarisi 102 dakika ile en kısa sürede eğitim işlemini tamamlarken, NasNet Large mimarisi 10212 dakika ile en uzun sürede eğitim işlemini tamamlamıştır.

4. veri seti için kullanılan Ön Eğitimli KSA mimarilerinin, manuel olarak etiketleme işlemi ile belirlenen parametre sınıfları için yaptığı tahminler neticesinde elde ettiği doğruluk yüzdeleri, her bir devirde (epoch) yapmış olduğu iterasyon sayıları ve analiz süreleri karşılaştırmalı olarak Çizelge 6.5'te verilmiştir. Şekil 6.70'te söz konusu Ön Eğitimli KSA mimarilerinin 4. veri seti (üçü beraber) için doğruluk yüzdelerini içeren grafik, Şekil 6.71'de de analiz sürelerini gösteren grafik verilmiştir. Ayrıca 4.veri seti içinde yer alan her bir mimari için iterasyona bağlı doğruluk ve kayıp değişimi grafikleri sırasıyla Şekil 6.72-Şekil 6.91'de verilmiştir.


Diğer taraftan, MATLAB programında yapılan analizler neticesinde Ön Eğitimli KSA mimarilerinin doğruluk yüzdelerini tespit ederken cephe görselleri üzerinde yoğunlaştığı bölgeleri içeren ısı haritalı (heatmap) görseller de Şekil 6.92'de verilmiştir.

Çizelge 6.5. 4. veri seti (çok sınıflı sınıflandırma) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları

Ön Eğitimli KSA Türü	Doğruluk Yüzdesi	İterasyon Sayısı	Analiz Süresi (Dakika)
VGG-19	78,12	1055	5685
ResNet-50	77,65	527	451
ResNet-101	76,89	1055	955
Inception ResNetV2	75,66	263	768
SqueezeNet	67,99	131	233
Xception	73,48	131	1352
ShuffleNet	72,54	263	532
DarkNet-53	78,88	263	388
NasNet Large	77,46	2111	9645
EfficientNet	74,81	263	1025




Şekil 6.70. 4. veri seti (çok sınıflı sınıflandırma) için Ön Eğitimli KSA mimarilerinin karşılaştırmalı sonuçları




Şekil 6.71. 4. veri seti (bitişik nizamlılık durumu) için Ön Eğitimli KSA mimarilerinin analiz süreleri mukayesesi

Not: NasNet Large mimarisinin devir (epoch) sayısının 20 olarak hesaplarda dikkate alındığı unutulmamalıdır.




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.72. İkili sınıflandırma (VGG-19) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.73. İkili sınıflandırma (VGG-19) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.74. İkili sınıflandırma (ResNet-50) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.75. İkili sınıflandırma (ResNet-50) iterasyona bağlı kayıp değişimi



Şekil 6.76. İkili sınıflandırma (ResNet-101) iterasyona bağlı doğruluk değişimi




Şekil 6.77. İkili sınıflandırma (ResNet-101) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.78. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.79. İkili sınıflandırma (Inception ResNetV2) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.80. İkili sınıflandırma (SqueezeNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.81. İkili sınıflandırma (SqueezeNet) iterasyona bağlı kayıp değişimi



Şekil 6.82. İkili sınıflandırma (Xception) iterasyona bağlı doğruluk değişimi




Şekil 6.83. İkili sınıflandırma (Xception) iterasyona bağlı kayıp değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.84. İkili sınıflandırma (ShuffleNet) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzeltilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.85. İkili sınıflandırma (ShuffleNet) iterasyona bağlı kayıp değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama

Şekil 6.86. İkili sınıflandırma (DarkNet-53) iterasyona bağlı doğruluk değişimi




— Eğitim (Düzleştirilmiş)
 —●— Eğitim
 -●- Doğrulama


Şekil 6.87. İkili sınıflandırma (DarkNet-53) iterasyona bağlı kayıp değişimi




řekil 6.88. İkili sınıflandırma (NasNet Large) iterasyona bađlı dođruluk deđiřimi



řekil 6.89. İkili sınıflandırma (NasNet Large) iterasyona bađlı kayıp deđiřimi




Şekil 6.90. İkili sınıflandırma (EfficientNet) iterasyona bağlı doğruluk değişimi



Şekil 6.91. İkili sınıflandırma (EfficientNet) iterasyona bağlı kayıp değişimi




Manuel Etiketlenen Cephe Görsele



Ön Eğitimli KSA Kararı



Manuel Etiketlenen Cephe Görsele



Ön Eğitimli KSA Kararı



Manuel Etiketlenen Cephe Görsele



Ön Eğitimli KSA Kararı

Şekil 6.92. 4. veri seti (çok sınıflı sınıflandırma) için Ön Eğitimli KSA mimarilerinin ısı haritası örnekleri

Çizelge 6.4'te gösterildiği gibi, Google Street View üzerinden elde edilen bina cephe görsellerinin manuel olarak etiketlenmesi neticesinde oluşturulan 4. veri seti (çok sınıflı sınıflandırma) için tez çalışması kapsamında kullanılan Ön Eğitimli KSA modelleri vasıtasıyla ilk 3 veri seti ile ikili sınıflandırma stratejisi uyarınca doğrulukları sınıanan 3 parametrenin tamamı çok sınıflı sınıflandırma strateji yardımıyla yüksek doğruluk oranı ile tespit edilmiştir. Ayrıca, elde edilen doğruluk oranlarının yanı sıra ısı haritalarının (Şekil 6.92) binanın ilgili parametreleri için odaklanması gereken noktalara yoğunlaşmış ve yoğunlaşmadığı da sınıanmış ve bu noktada da başarılı

sonular elde edilmiřtir. Kullanılan n Eđitimi KSA modelleri ile 4. veri seti iin en yksek dođruluk oranı DarkNet-53 mimarisi yardımıyla %78,88 olarak elde edilmiř iken en dřk dođruluk oranı da SqueezeNet mimarisi yardımıyla %67,99 olarak belirlenmiřtir. izelge 6.4'teki dođruluk yzdeleri incelendiđinde yaklařık %10'luk bir spektrumda dođruluk yzdesi farklılıđı olduđu grlmektedir.

Diđer taraftan, sz konusu n Eđitimi KSA modelleri ile yapılan hesaplamalar dhilinde analiz sreleri mukayase edildiđinde SqueezeNet mimarisi 233 dakika ile en kısa srede eđitim iřlemini tamamlarken, NasNet Large mimarisi 9645 dakika ile en uzun srede eđitim iřlemini tamamlamıřtır.

Tez kapsamında tanzim edilen 4 veri seti dhilinde icra edilen 40 analiz neticesinde elde edilen dođruluk yzdeleri ve analiz sreleri arasındaki farklılıkların; her bir n Eđitimi KSA modelinin 5. Blmde ifade edilen kendine has zelliklerinden (evriřim sayıları, kanal karıřtırma zelliđi, toplu normalleřtirme, havuzlama vb.), katman (layer) sayıları ve katmanlar ierisindeki nron sayılarından, her bir devir (epoch) ierisindeki iterasyon sayılarından kaynaklanmaktadır. Ayrıca, bahse konu mimarilerin yapılan tez alıřması kapsamında; bina cephe grselleri zerinden tespit edilen parametreler dhilinde grnt iřlemeye dair kabiliyetleri ve yatkınlıklarından kaynaklanmakta olduđu da unutulmamalıdır.

7. SONUÇLAR VE ÖNERİLER

Yaşanabilecek olası bir depremin öncesinde proaktif önlemlerin alınabilmesi açısından mevcut betonarme binaların hızlı sismik risk değerlendirmelerinin yüksek doğrulukla ve olabildiğince hızlı bir şekilde belirlenmesi oldukça büyük önem arz etmektedir. Ancak ülkemizde yaşanabilecek olası bir depremde gerek yürürlükte olan yönetmelikler kapsamındaki hususlara uyulmaması gerekse uygulamada uygulama kaynaklı hatalar nedeniyle beklenen performans gösteremeyecek yüz binlerce betonarme binanın, mevcut yapı stoğu içerisinde büyük yer kaplaması önemle üzerinde durulması ve ciddi reaksiyon alınması gereken bir husus olarak görülmektedir. Söz konusu mevcut betonarme binaların sayıca çok fazla olmasından dolayı yönetmelikler kapsamında detaylı deprem performanslarının ve risk durumlarının belirlenmesi çok büyük bir bütçe ve zaman gerektirmektedir. Ayrıca, hızlı sismik değerlendirilmesi yapılacak olan mevcut betonarme binaların fazla olması çok sayıda uzman/mühendis görevlendirilmesine de sebep olacaktır.

Diğer taraftan, deprem risk analizinin çok sayıda farklı parametreye bağlı olması sebebiyle de değerlendirmeye tabi tutulan betonarme binaların performanslarına ve risk öncelik durumlarına ilişkin kararların mümkün olduğunca standart, hızlı ve ölçülebilir şekilde alınması hem ekonomik anlamda hem de zaman tasarrufu anlamında yadsınamaz bir fayda sağlayacaktır.

Hızlı sismik değerlendirmede ele alınacak parametre sayısı oldukça fazladır. Bu parametrelerin bir kısmı binaların geometrik özellikleri ile binalardaki düzensizliklerin mevcudiyeti, bir kısmı binaların mekanik özellikleri olarak ifade edebileceğimiz; malzeme özellikleri ve dayanımı (beton dayanımı, donatı dayanımı, donatı düzeni ve detaylandırması vb.) ve bir diğer kısmı ise binaların bulunduğu bölgenin depremselliği, zemin özellikleri, zemin durumu vb. parametrelerle ilgilidir. Çizelge 3.3'te her bir yöntemin içeriğinde yer alan parametreler detaylı olarak verilmiştir.

Bu doktora tez çalışması ile mevcut betonarme binaların deprem performansını ve risk öncelik durumunu etkileyen ve literatürdeki hızlı sismik değerlendirme yöntemlerinde oldukça önemli yer kaplayan geometrik parametrelerden olan; ağır çıkma varlığı, bitişik nizamlılık durumu, eğimli arazi varlığı durumlarının Google Street View üzerinden toplanan bina cephe görsellerinin manuel olarak etiketlenmesi ve 10 adet Ön Eğitimli KSA mimarisi ile yapılan analizler neticesinde de söz konusu etiketlerin sınanması sonucunda büyük doğruluk yüzdeleri ile tespit edilebildiği ortaya konulmuştur.

Ayrıca, bu doktora tez çalışması ile mevcut betonarme binaların olası bir deprem öncesinde hızlı sismik risk değerlendirmesinde önem arz eden parametrelerden olan; ağır çıkma varlığı, bitişik nizamlılık durumu, eğimli arazi varlığı durumlarının; literatürde verilen hızlı değerlendirme yöntemlerinden farklı olarak Google Street View üzerinden toplanan bina cephe görsellerinin Ön Eğitimli KSA mimarileri kullanılmak suretiyle çok daha kısa sürede ve yüksek doğrulukla belirlenmesi sağlanmıştır.

7.1. Sonuçlar

Türkiye gibi deprem açısından büyük risk altında olan bir coğrafyada gerçekleşebilecek olası bir deprem öncesinde mevcut betonarme binaların hızlı sismik değerlendirilmesi hususunun büyük önem taşıması düşüncesinden hareketle bu tez çalışmasında aşağıdaki sonuçlar elde edilmiştir:

- Çalışmada Google Street View üzerinden toplanan bina cephe görsellerinden, söz konusu parametreler açısından uygun olan 4500 adedi kullanılmıştır. Bu verilere aynalama ve gürültü işlemleri uygulanmak suretiyle veri setlerindeki bina cephe görselleri artırılmıştır. Ağır çıkma varlığının tespiti için teşkil edilen 1. veri setinde 5467, bitişik nizamlılık durumu için teşkil edilen 2. veri setinde 6170, eğimli arazi varlığı için teşkil edilen 3. veri setinde 7107, çok sınıflı sınıflandırma için teşkil edilen 4. veri setinde ise 5280 adet bina cephe görseli kullanılmıştır.
- Bu tez çalışmasında 4 farklı veri seti teşkil edilmiş, her bir veri seti için de bahsi geçen 10 adet Ön Eğitilmiş KSA yapısı ile analiz yapılmış olup toplam 40 adet analiz gerçekleştirilmiştir. Kullanılan Ön Eğitilmiş KSA modelleri ile her bir veri seti için elde edilen maksimum, minimum ve ortalama doğruluk yüzdeleri sırasıyla Çizelge 7.1’de verilmiştir.

Çizelge 7.1. Her bir veri seti için Ön Eğitilmiş KSA mimarilerinin maksimum ve minimum doğruluk yüzdeleri

Veri Seti Sınıfı	Analiz Türü	Maksimum Doğruluk	Minimum Doğruluk	Ortalama Doğruluk Yüzdesi
		Yüzdesi/Ön Eğitilmiş KSA Modeli	Yüzdesi/Ön Eğitilmiş KSA Modeli	
1. Veri Seti (Ağır Çıkma)	İkili Sınıflandırma	%88,62/ DarkNet-53	%80,56/ Inception ResNetV2	%85,46
2. Veri Seti (Bitişik Nizam)	İkili Sınıflandırma	%96,68/ DarkNet-53	%91,40/ ShuffleNet	%94,71
3. Veri Seti (Eğimli Arazi)	İkili Sınıflandırma	%93,06/ ResNet-50	%86,35/ NasNet Large	%90,37
4. Veri Seti (Üçü Beraber)	Çok Sınıflı Sınıflandırma	%78,88/ DarkNet-53	%67,99/ SqueezeNet	%75,35

Not: Kullanılan Metrik: Ortalama Sınıflandırma Doğruluğu

- Söz konusu başarı oranları her bir parametre için farklıdır. Bu farklılıklar her bir Ön Eğitilmiş KSA modelinin 5. Bölümde ifade edilen kendine has özelliklerinden (evrişim sayıları, kanal karıştırma özelliği, toplu normalleştirme, havuzlama vb.), katman (layer) sayıları ve katmanlar içerisindeki nöron sayılarından, her bir devir (epoch) içerisindeki iterasyon sayılarından ve yapmış olduğumuz tez çalışması kapsamında bina cephe görselleri üzerinden tespit edilen parametreler dâhilinde görüntü işlemeye dair kabiliyeti ve yatkınlığından

kaynaklanmaktadır. Bununla beraber dört farklı veri seti grubunda; 1. 2. ve 4. veri setlerinin DarkNet-53 mimarisi ile yüksek bir doğruluk oranına ulaştığı görülmektedir. Özellikle 2. veri setinin doğruluk oranının %96,68 olarak elde edilmiş olması önemlidir. Zira literatürde benzer yapı ve deprem mühendisliği problemleri üzerine yapılan çalışmalarda başarı genellikle sınırlı düzeyde kalmaktadır. Örneğin Ma ve ark. (2020) DarkNet-53 mimarisini kullanarak deprem sonrası hasarlı binaların tespitini bina görselleri üzerinden gerçekleştirmiş ve %90,89'luk bir başarı elde etmiştir. Ji ve ark. (2018) %78,6, Wen ve ark. (2015) %82,21, Zao ve ark. (2018) %88,45'lik bir başarıya ulaşmışlardır. Huang ve ark. (2021) ise ResNet-50 mimarisini kullanarak betonarme köprü kirişlerinde hasarların sınıflandırılması için DÖ tabanlı bir görsel kusur tespit sistemi gerçekleştirmiş ve kusur tespitinde %90,4 oranında bir doğruluk elde etmişlerdir.

- Ön Eğitimli KSA modelleri ile yapılan hesaplamalar dâhilinde analiz süreleri mukayese edildiğinde her bir veri seti için elde edilen maksimum ve minimum analiz süreleri sırasıyla Çizelge 7.2'de verilmiştir.

Çizelge 7.2. Her bir veri seti için Ön Eğitimli KSA mimarilerinin maksimum ve minimum analiz süreleri

Veri Seti Sınıfı	Maksimum Analiz Süresi	Minimum Analiz Süresi
	(Dakika) /Ön Eğitimli KSA Modeli	(Dakika) /Ön Eğitimli KSA Modeli
1.Verit Seti (Ağır Çıkma)	9868/ NasNet Large	102/ Xception
2.Verit Seti (Bitişik Nizam)	9334/ NasNet Large	97/ SqueezeNet
3.Verit Seti (Eğimli Arazi)	10212/ NasNet Large	102/ SqueezeNet
4.Verit Seti (Üçü Beraber)	9645/ NasNet Large	223/ SqueezeNet

- Her bir veri setinde bulunan bina cephe görseli sayısının çokluğu düşünüldüğünde; Çizelge 7.2'de verilen analiz süreleri mukayese edildiğinde 2. 3. ve 4. veri setlerinin SqueezeNet mimarisi ile mevcut betonarme binaların hızlı sismik değerlendirilmesinde kullanılan parametreleri oldukça kısa sürede ve Çizelge 7.1. de dikkate alındığında yüksek doğrulukla belirlediği açıktır. Bu noktada söz konusu mimarinin, analiz süresi açısından da diğer mimarilere nispetle başarılı bir performans sergilediğini söylemek mümkündür. Ayrıca, analiz sürelerinin ciddi farklılıklar göstermesinde ve bazı analizlerin oldukça uzun sürmesinde (örneğin Nasnet Large mimarileri) doğruluk oranları için ifade edilen hususlara ilave olarak söz konusu analizlerin yapıldığı bilgisayarda bellekle ilgili yeterli kapasite olmadığından bu noktada yığın boyutunun maksimum 32 alınabilmesi oldukça etkili olmuştur. Bu değer artırılması durumunda tüm mimariler için analiz sürelerinin bir miktar daha kısalcacağı değerlendirilmektedir.

- Tez çalışması kapsamında Google Street View üzerinden toplanan bina cephe görselleri manuel olarak etiketlenmiş ve söz konusu etiketlerin Ön Eğitimli KSA mimarileri ile yüksek doğrulukla tahmini yapılmıştır. Yu ve ark. (2020) cadde üzerinden alınan görsellerle yapılarda yumuşak kat varlığını DÖ ile tahmin eden bir algoritma çalışmışlar ve ResNet-50 mimarisinin %85,94'lük bir başarıya ulaştığı görülmüştür.
- Tez çalışması kapsamında 1. veri seti (ağır çıkma) özelinde yapılan analizlerden; ResNet-101, Inception ResNetV2 ve SqueezeNet algoritmalarına ilişkin iterasyona bağlı kayıp grafikleri incelendiğinde (Şekil 6.8, Şekil 6.10, Şekil 6.12) ezberleme (overfit) durumunun gerçekleştiği görülmektedir. Literatürde yapılan çalışmalar incelendiğinde; ezberleme probleminin çözümü için çoğunlukla veri setindeki görsel sayılarının artırıldığı ya da seyreltme (dropout) değerinin 0,5 alınması suretiyle söz konusu katmanın da mimarilere eklendiği görülmektedir. Bu noktadan hareketle tüm veri setlerinde yer alan tüm Ön Eğitimli KSA mimarileri için seyreltme değeri 0,5 olarak uygulanmıştır. Ayrıca, eğer problem veri setindeki görsel sayılarının yetersiz kalması olsa idi aynı veri seti için yapılan diğer analizler neticesinde elde edilen iterasyona bağlı kayıp grafiklerinde de benzer ezberleme durumunun gerçekleşmesi gerekirdi. Bununla beraber Kang ve ark. (2017) tarafından yapılan çalışmada, aynı veri seti için kullanılan Ön Eğitimli KSA mimarilerinden olan AlexNet, VGG-16, ResNet-18 ve ResNet-34 arasından yalnızca ResNet-34 ile yapılan analiz neticesinde ezberleme durumunun ortaya çıktığı tespit edilmiştir. Dolayısı ile ezberleme durumunun ortadan kaldırılması için literatürde uygulanan yöntemlerin icra edilmesine rağmen söz konusu problemin devam ettiği de görülmüştür.
- Tez çalışmasında oluşturulan genel akış şemaları ve stratejiler kullanılmak suretiyle DÖ ve görüntü işleme alanında ortaya atılacak yeni algoritmalar ile mevcut veri setlerini kullanarak yeni analizler gerçekleştirmek mümkün olabilecektir. Bu açıdan bakıldığında, yapılan tez çalışması söz konusu alanlara kolaylıkla entegre olabilecek ve güncelliğini de koruyabilecektir.
- Tez kapsamında oluşturulan her bir veri setinin Türkiye'deki yapı stoğu içerisinde yer alan betonarme binaları temsil özelliği ile tespit edilen parametrelerin hızlı sismik değerlendirme yöntemlerine uyumu göz önünde bulundurulduğunda bu çalışmada revize edilerek kullanılan Ön Eğitimli KSA modellerinin bina cephe görselleri üzerinden söz konusu parametreleri belirlemede büyük başarı elde ettiği gerçeği dikkate alındığında literatürde oluşan boşluğun doldurulması açısından büyük önem arz etmektedir.

7.2. Öneriler

Tez çalışması kapsamında mukayese edilen Ön Eğitimli KSA yapılarının doğruluk oranları her ne kadar kabul edilebilir ve yüksek oranlarda olsa da yeterli görülmemeli ve farklı Ön Eğitimli KSA modelleri (AlexNet, GoogleNet, DenseNet, YOLOv3, VGG-16 vb.) kullanılmalı ve DÖ yöntemleri geliştirilmelidir ki, böylelikle daha yüksek doğruluk oranlarının elde edilmesi de mümkün olsun.

Bu tez çalışması kapsamında yapılan analizlerde dikkate alınan parametreler Çizelge 6.1’de, her bir devir (epoch) içerisinde yer alan iterasyon sayıları da Çizelge 6.2, Çizelge 6.3, Çizelge 6.4, Çizelge 6.5’te verilmiştir. Söz konusu parametrelerin değerleri değiştirilerek doğruluk yüzdelerinin artırılması sağlanabilir.

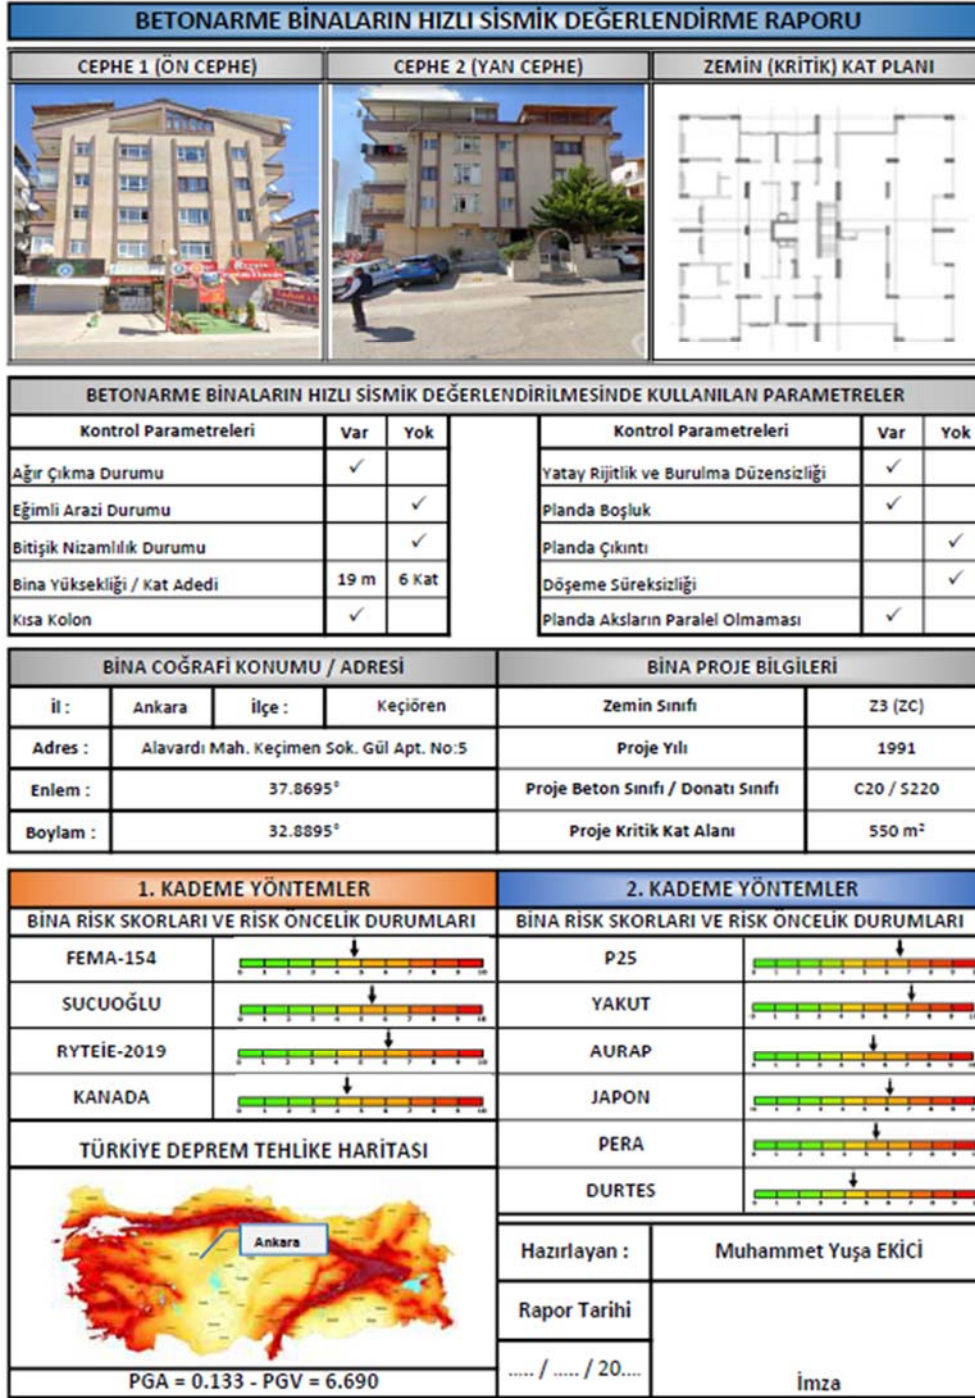
Tez çalışması kapsamında dikkate alınan 10 farklı Ön Eğitimli Konvolüsyonel Sinir Ağı ile yapılan analizlerde Google Street View üzerinden toplanan bina cephe görselleri, RGB renk uzayı kullanılmak suretiyle değerlendirmeye tabi tutulmuştur. Bu noktadan hareketle sonraki çalışmalarda yalnızca siyah-beyaz renk spektrumları kullanılarak söz konusu analizler yapılabilir.

Bu tez çalışmasının erişilmek istenen son evresi olan paket bir yazılım haline evrilerek ticarileşmesi aşağıda belirtilen hususların gerçekleştirilmesi ile mümkün olacaktır:

- Bu doktora tezi kapsamında bina cephe görselleri üzerinden belirlenen parametrelere ilave olarak benzer şekilde bina cephe görselleri üzerinden bina yüksekliği, kısa kolon varlığı, yumuşak kat/rijit kat varlığı tespit edilmeli ve bina kat planları üzerinden de kolon-perde-taşıyıcı duvar konumları ve alanları, döşemede var olan boşluk miktarı, planda çıkıntı olması durumu, planda aksların paralel olmaması gibi mevcut betonarme binaların hızlı sismik değerlendirilmesinde elzem olan parametreler yüksek doğruluk oranı ile tespit edilmeli.
- Mevcut betonarme binaların beton ve donatı dayanımları, yapım yılı, zemin sınıfı, yapının yaklaşık zemin kat alanı gibi parametreler eğer proje mevcutsa proje üzerinden değerlendirilmeli. (Beton ve donatıların gerçek (yerinde) dayanımlarının tespiti ile ilgili saha çalışmaları ancak detaylı deprem analizlerinde gerekli olmakta ve detaylı malzeme analizleri hızlı değerlendirme yöntemlerinde yapılmamaktadır.) Projesi mevcut olmayan binaların ise değerlendirilmesi sadece 1. kademe yöntemler ile yapılmalı.
- İncelenen betonarme binanın coğrafi koordinatları ya da adresi de belli olacağı için yapının lokasyonuna bağlı olarak AFAD-Türkiye Deprem Tehlike Haritası üzerinden en büyük yer ivmesi (PGA) ve/veya en büyük yer hızı (PGV) değerleri de elde edilerek yapının hızlı sismik değerlendirilmesi için gerekli deprem yükü parametreleri de tespit edilmeli.
- Bazı değerlendirme yöntemlerinde kullanılan mevcut binada korozyonun varlığı, kolon ve kirişlerdeki etriye aralığı, kolon ve perdelerdeki boyuna donatı oranları ve aralıkları gibi

detaylı saha çalışması ile tespit edilebilecek olan yapısal parametreler ise binanın varsa projesi üzerindeki yapım yılı bilgilerine bağlı minimum değerler baz alınarak değerlendirilmeli.

- Bu çalışmalar silsilesi ile elde edilecek olan parametreler ile yapınının coğrafi bilgileri ve varsa proje bilgileriyle birleştirilmesi sonucunda son aşamada bir değerlendirme raporu elde edilmeli. Projesi olmayan binalar için sadece cephe görselleri kullanılarak 1. kademe yöntemlerine ait skorlar tespit edilmeli. Projesi ve cephe görselleri olan binalar için ise hem 1. kademe hem de 2. kademe yöntemlerine ait skorlar elde edilebilmeli ve tüm bu skora göre yapı için bir karne hazırlanmalı.
- Literatürde 1. kademe ve 2. kademe yöntemlerinin birbirinden farklı sonuçlar verdiği bilinmektedir. Bu nedenle elde edilen giriş parametrelerine bağlı olarak literatürde uygun olan değerlendirme yöntemlerine göre binanın genel bir risk puanı belirlenmeli.
- Netice itibarı ile yukarıda bahsi geçen önerilerin entegrasyonu yapılarak oluşturulacak bütünlük bir sistematik ile binaların hızlı sismik değerlendirilmesi konularında ileriki çalışmalarda nihai hedef olan hızlı sismik değerlendirme için giriş parametrelerinin tespitinin yapılması literatür açısından önemli bir açığın doldurulmasını sağlayacaktır. (Arslan ve ark. (2021) tarafından patent başvurusu yapılmış olan ‘‘Konut Türü Binaların Deprem Risk Önceliklerinin Tespitinde Kullanılan Geometrik Parametrelerin Evrişimli Sinir Ağları ile Belirlenmesi Yöntemi’’ adlı çalışma ile bu açığın doldurulması hedeflenmektedir) Ayrıca, böyle bir çalışmanın yapılması neticesinde Şekil 7.1’deki gibi bir değerlendirme raporunun da teşkil edilmesi uygun olacaktır.



Şekil 7.1. Değerlendirme rapor çıktısı örneği

- Ayrıca, tez çalışması kapsamında kullanılan Ön Eğitilmiş KSA mimarileri her ne kadar bina cephe görselleri üzerinden hızlı sismik değerlendirme yöntemlerinde sıklıkla kullanılan parametreleri yüksek doğruluk oranı ile tespit etse de ısı haritaları (heatmap) detaylı bir şekilde incelendiğinde bahse konu mimarilerin söz konusu görseller üzerinde, tespiti yapılacak parametreye uygun olmayan noktalara (örneğin bitişik nizam bir bina için gökyüzüne, zemine ve ağaç-araba gibi bir nesneye odaklanması) odaklanarak doğru tespitler yaptığı da göz ardı edilmemelidir.

- Dięer taraftan, bu alıřmada Google Street View zerinden toplanan bina cephe grselleri, herhangi bir binanın yalnızca caddeye bakan kısımlarından ve oęunlukla tek cephesinden alınabilen bir muhteviyata sahiptir. Doęal olarak bir binada aęır ıkma olup olmadıęına, bitişik veya ayırık nizam olduęuna, eęimli arazi zerine inřa edilip edilmedięine; sz konusu binanın drt cephesinden elde edilen grsellerin kompoze edilerek deęerlendirilmesi neticesinde eriřilir. nk bir binanın herhangi bir cephesinde bahse konu parametrelerden herhangi birinin var ya da yok olması o parametreye iliřkin sonucu deęiřtirecektir. Bu nedenle bir bina ile ilgili daha doęru karara varabilmek iin binanın eriřilebilen tm cephe grsellerine bakılmalıdır.



KAYNAKLAR

- Achs, G., Adam, C., 2012, Rapid Seismic Evaluation of Historic Brick-Masonry Buildings in Vienna (Austria) Based on Visual Screening, *Bull Earthquake Eng*, 10:1833–56. <https://doi.org/10.1007/s10518-012-9376-5>.
- Adler, D., 2015, The Mexico City Earthquake, 30 Years on: Have The Lessons Been Forgotten?, *The Guardian*, <https://www.theguardian.com/cities/2015/sep/18/mexico-city-earthquake-30-years-lessons>.
- Aldemir, A., Güvenir, E., Şahmaran, M., 2020, Rapid Screening Method for The Determination of Regional Risk Distribution of Masonry Structures, *Structural Safety*, 85, 101959.
- Ali, N., Khan, W., Chaiyasarn, K., 2019, Damage Detection and Localization in Masonry Structure Using Faster Region Convolutional Networks, *International Journal of GEOMATE*, Vol.17, Issue 59, pp.98-105.
- Alirezaei, A., Vahdani, S., 2015, Estimation of Seismic Deformation Demands of Tall Buildings with Symmetric Setbacks, *World Academy of Science, Engineering and Technology International Journal of Civil and Environmental Engineering*, Vol:9, No:4.
- Altınar, M., 2008, Deprem Etkisindeki Betonarme Binaların Göçme Riskinin Saptanması için Hızlı Değerlendirme Yöntemleri, Yüksek Lisans Tezi, *İstanbul Kültür Üniversitesi*.
- Arslan, M. H., 2009, Application of ANN to Evaluate Effective Parameters Affecting Failure Load and Displacement of RC Buildings, *Natural Hazards and Earth System Sciences*, 9, 967–977.
- Arslan, M. H., 2010, An Evaluation of Effective Design Parameters on Earthquake Performance of RC Buildings Using Neural Networks, *Engineering Structures*, Volume 32, Issue 7, Pages 1888-1898.
- Arslan, M. H., Ceylan M., Koyuncu, T., 2012, An ANN Approaches on Estimating Earthquake Performances of Existing RC Buildings, *Neural Network World*, 5/12, 443-458.
- Arslan, M. H., Ceylan, M., Koyuncu, T., 2015, Determining Earthquake Performances of Existing Reinforced Concrete Buildings by Using ANN, *World Academy of Science, Engineering and Technology International Journal of Civil and Environmental Engineering*, 9, 8, 1089-1093.
- Arslan, M. H., Yavariabdı, A., Doğan, G., Ekici, M. Y., Aşık, F. M., 2021, Konut Türü Binaların Deprem Risk Önceliklerinin Tespitinde Kullanılan Geometrik Parametrelerin Evrişimli Sinir Ağları ile Belirlenmesi Yöntemi, *Türk Patent Enstitüsü*, <https://hdl.handle.net/20.500.13091/2230>.
- Ashames, Y. Y. A., 2020, Derin Öğrenme Yöntemleri Kullanılarak Osteoporozun Belirlenmesi, Yüksek Lisans Tezi, *Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*, Konya.
- Atabey, V., 2022, <https://volkanatabey.com.tr/planda-cikinti-bulunmasi-a3-duzensizligi-tbdy-2018/>. [Ziyaret Tarihi: 12.04.2022].
- Bal, İ. E., Özdemir, Z., 2006, Çevre Çerçeve Kirişi Süreksizliğinin Yapı Deprem Davranışı Üzerine Etkileri, *İMO Bülten*, Sayı:87/2006, İstanbul.

- Bal, İ. E., Tezcan, S.S., Gülay, F. G., Ekim 2007, Betonarme Binaların Göçme Riskinin Belirlenmesi İçin P25 Hızlı Değerlendirme Yöntemi, *Altıncı Ulusal Deprem Mühendisliği Konferansı*, İstanbul.
- Baltacıoğlu, A. K., Cıvlek, Ö., Akgöz, B., Korkmaz, A., 2010, Deprem Hasarlarının Hızlı Tespitinde Yapay Sinir Ağları Yaklaşımı, *Mühendislik Bilimleri ve Tasarım Dergisi*, 1, 1, 22-27.
- Bingöl, K., Akan, A. E., Örmecioğlu, H. T., Er, A., 2020, Depreme Dayanıklı Mimari Tasarımda Yapay Zekâ Uygulamaları: Derin Öğrenme ve Görüntü İşleme Yöntemi ile Düzensiz Taşıyıcı Sistem Tespiti, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35:4 (2020) 2197-2209.
- Boduroğlu, H. M., Özdemir, P., İlki, A., Şirin, S., Demir, C., Baysan, F., Ağustos 2004, Towards a Modified Rapid Screening Method for Existing Medium Rise RC Buildings in Turkey, *13th World Conference on Earthquake Engineering*, Vancouver, Canada.
- Boduroğlu, H., Çağlayan, P. Ö., 2007, Mevcut Yapıların Değerlendirmesinde Bir Tarama Yöntemi, *Altıncı Ulusal Deprem Mühendisliği Konferansı*, İstanbul.
- Burke, G., 2017, How Extensive Damage in Mexico City's Earthquake Could Have Been Averted, *Associated Press*.
- Bülbül, M. A., Harirchian, E., Işık, M. F., Hosseini, S. E. A., Işık, E., 2022, A Hybrid ANN-GA Model for an Automated Rapid Vulnerability Assessment of Existing RC Buildings, *Applied Sciences*, 12, 5138.
- Calp, M. H., 2022, <https://arxiv.org/ftp/arxiv/papers/1902/1902.04412.pdf> [Ziyaret Tarihi: 11.04.2022].
- Celep, Z., Kara, N., 2012, Nonlinear Seismic Response of Structural Systems Having Vertical Irregularities due to Discontinuities In Columns, *15 WCEE*, Lisboa.
- Cengiz, E., 2020, Endoskopi Görüntülerindeki Poliplerin Derin Öğrenme Algoritması Kullanılarak İncelenmesi, *Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir.
- Ceylan, Z. ve Bulkan, S., 2018, Türkiye Ulaşım Kaynaklı Enerji İhtiyacının Hibrit ANFIS-PSO Metodu ile Tahmini, *AKÜ FEMÜBİD*, 18 (2), 740-750, DOI: 10.5578/fmbd.67331.
- Charleston, A., 2014, Promoting Earthquake – Resistant Construction in Developing Countries, *Earthquake Hazard Centre*, vol.18 no.1 Temmuz 2014.
- Choi, N., Son, H., Kim, C., 2008, Rapid 3D Object Recognition for Automatic Project Progress Monitoring Using A Stereo Vision System, *The 25th International Symposium on Automation and Robotics in Construction*, June 26-29.
- Chollet, F., 2017, Xception: Deep Learning with Depthwise Seperable Convolutions, *arXiv:1610.02357v3 [cs.CV]*.
- Cole, G. L., Dhakal R. P., Chouw, N., 2012, Building Pounding Damage Observed İn The 2011 Christchurch Earthquake, *15 WCEE*, Lisboa.
- Çağatay, İ. H., Korkmaz, K., İnan, T., 2011, An Investigation on Plan Geometries of RC Buildings: with or without Projections in Plan, Adana.

- Coşkun, O., Aldemir, A., Şahmaran, M., 2020, Rapid Screening Method for the Determination of Seismic Vulnerability Assessment of RC Building Stocks, *Bulletin of Earthquake Engineering*, 18:1401–1416.
- Çelik, O. C., İlki, A., Yalçın, C., Yüksel, E., Ekim 2007, Doğu ve Batı Avrupa Ülkelerinde Değişik Tip Binaların Deprem Riskinin Hızlı Değerlendirilmesi Üzerine Bir Deneyim, *Altıncı Ulusal Deprem Mühendisliği Konferansı*, İstanbul.
- Çelik T., Öztörün N. K., Damcı E., Yıldızlar B., Gürsoy G., 2003, Bakırköy Özelinde Türkiye Genelinde Yapı Durum Tespiti için Bir Algoritma, *Beşinci Ulusal Deprem Mühendisliği Konferansı*, 63-64, İstanbul, Türkiye, 26-30 Mayıs.
- Dao, V., Adeli, H., Ly, H., Le, L., Le, V., Le, T., Pham, B., 2020, A Sensitivity and Robustness Analysis of GPR and ANN for High-Performance Concrete Compressive Strength Prediction Using a Monte Carlo Simulation, *Sustainability*, 12, 830; doi:10.3390/su12030830.
- D’Ayala, D., 2012, Assessing the Seismic Vulnerability of Masonry Buildings, Handbook of Seismic Risk Analysis and Management of Civil Infrastructure Systems Oxford, *Woodhead Publishing*; 2013. p. 334–65. <https://doi.org/10.1533/9780857098986.3.334>.
- Demirkol, Z., 2019, Herkes için Yapay Zekâ, Devrim Yalkut, İstanbul.
- Doğan, G., Arslan, M. H., Baykan, Ö. K., 2020, Determination of Damage Levels of RC Columns with A Smart System Oriented Method, *Bulletin of Earthquake Engineering*, 18, pages 3223–3245.
- Doğan, T. P., Kızılkula, T., Mohammadi, M., Erkan, İ. H., Kabaş, H. T., Arslan, M. H., 2021, A Comparative Study on the Rapid Seismic Evaluation Methods of Reinforced Concrete Buildings, *International Journal of Disaster Risk Reduction*, DOI: 10.1016/j.ijdr.2021.102143.
- Dritsos, Stephanos E., Moseley, V. J., 2013, A Fuzzy Logic Rapid Visual Screening Procedure to Identify Buildings at Seismic Risk, *Beton – Und Stahlbetonbau*, Special Issue: SI. 2013, 136-143.
- Elnashai A. S., Gencturk, B., Kwon, O., Hashash Y., Kim, J., 2010, The Maule (Chile) Earthquake Consequence Assessment and Case Studies, Chile.
- Er, M. B., 2022, <https://dergipark.org.tr/en/download/article-file/1170269> [Ziyaret Tarihi: 14.04.2022].
- Ertel, W., 2009, Under Graduate Topics Computer Science: Introduction to Artificial Intelligence, Heidelberg New York: Springer London Dordrecht.
- FEMA 154-ATC-21, 1998, Rapid Visual Screening of Buildings for Potential Seismic Hazards: A Handbook, Applied Technology Council, *Federal Emergency Management Agency*, Washington DC.
- FEMA 154, 2002, Rapid Visual Screening of Buildings for Potential Seismic Hazards: A handbook, Applied Technology Council, *Federal Emergency Management Agency*, Washington DC.

- FEMA 155-ATC-21-1. 1998, Rapid Visual Screening of Buildings for Potential Seismic Hazards: Supporting Documentation, Applied Technology Council, *Federal Emergency Management Agency*, Washington DC.
- FEMA 454, 2006, Designing for Earthquakes a Manuel for Architects, *Federal Emergency Management Agency*, Washington.
- Gongalez, D., Plata, D. R., Avevedo, A. B., Duque, L. C., Pollan, R. R., Betancourt, A., Garcia, S., 2020, Automatic Detection of Building Typology Using Deep Learning Methods on Street Level Images, *Building and Enviroment*, DOI: 10.1016/j.buildenv.2020.106805.
- Gongalez, D., Plata, D. R., Avevedo, A. B., Duque, L. C., Pollan, R. R., 2020, Use of deep learning models in street-level images to classify one-story unreinforced masonry buildings based on roof diaphragms, *Building and Enviroment*, DOI:10.1016/j.buildenv, 2020.107517.
- Google Developers, Google Street View API, 2007, Mountain View, California, USA.
- Griffiths, D., Boehm, J., 2018, Rapid Object Detection Systems, Utilizing Deep Learning and Unmanned Aerial Systems (UAS) for Civil Engineering Applications, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2, 2018 ISPRS TC II Mid-term Symposium "Towards Photogrammetry 2020"*, Riva del Garda, Italy.
- Guevara, L. L., 2012, "Soft Story" and "Weak Story" in Earthquake Resistant Design, A Multidisciplinary Approach, Facultad de Arquitectura Urbanismo, *Universidad Central de Caracas*, Venezuela.
- Guidelines for the Seismic Rehabilitation of Buildings (FEMA 273), 1997, *Federal Emergency Management Agency*, Washington, D. C., 435 s.
- Güler, A., 2005, Seismic Vulnerability Assessment Using Artificial Neural Networks, Yüksek Lisans Tezi, *Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı*, Ankara, 110s.
- Gülay, G. F., Tezcan, S. S., Bal, İ. E., Sevinç, S., Mayıs 2008, Binaların Deprem Güvenliği Konusunda Geliştirilen P25 Puanlama Yönteminin Kalibrasyonu ve Pilot Bölge Uygulaması, İstanbul.
- Gülay, F. G., Bal, İ. E., Gökçe, T., Çelik, N., September 2010, Fields Applications of P25 Preliminary Assessment Method for Identifying the Collapse Vulnerability of Existing RC Structures, *9th International Congress on Advances in Civil Engineering*, Trabzon, Turkey.
- Gülcü, A., Kuş, Z., 2022, <https://dergipark.org.tr/tr/download/article-file/739392> [Ziyaret Tarihi: 14.04.2022].
- Gültekin, B., 2022, "Betonarme Yapılarda Yapısal ve Yapısal Olmayan Hasarların Derin Öğrenme ile Tespiti", Yüksek Lisans Tezi, *Konya Teknik Üniversitesi*.
- Gürer, C., 2012, Deprem Nedeniyle Betonarme Yapılarda Oluşan Hasarlar, *Afyon Kocatepe Üniversitesi, İnşaat Mühendisliği Bölümü*, Ders Notları, Afyon.

- Güzel, Y., 2022, <https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-03-biyolojik-sinir-sistemi-ve-yapay-sinir-a%C4%9F%C4%B1-h%C3%BCcresi-6555add68d80> [Ziyaret Tarihi: 11.04.2022].
- Güzel, Y., 2022, <https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-5-%C3%A7ok-katmanl%C4%B1-yapay-sinir-a%C4%9F%C4%B1-4c6af075e1fe> [Ziyaret Tarihi: 11.04.2022].
- Harirchian, E., Lahmer, T., Rasulzade, S., 2020, Earthquake Hazard Safety Assessment of Existing Buildings Using Optimized Multi-Layer Perceptron Neural Network, *Energies*, 2020, 13, 2060.
- Harirchian, E., Lahmer, T., Kumari, V., Jadhav, K., 2020, Application of Support Vector Machine Modeling for the Rapid Seismic Hazard Safety Evaluation of Existing Buildings, *Energies*, 13, 3340.
- Harirchian, E., Lahmer, T., 15-18 May 2020, Improved Rapid Assessment Earthquake Hazard Safety of Structures via Artificial Neural Network. IOP Conference Series: Materials Science and Engineering, Volume 897, 2020, *5th International Conference on Civil Engineering and Materials Science (ICCEMS 2020)*, Singapore.
- Harirchian, E., Lahmer, T., 2020, Improved Rapid Visual Earthquake Hazard Safety Evaluation of Existing Buildings Using a Type-2 Fuzzy Logic Model, *Applied Sciences*, 10, 2375.
- Harirchian, E., Kumari, V., Jadhav, K., Raj Das, R., Rasulzade, S., Lahmer, T., 2020, A Machine Learning Framework For Assessing Seismic Hazard Safety of Reinforced Concrete Buildings, *Applied Sciences*, 10(20), 7153.
- Harirchian, E., Lahmer, T., 2020, Developing A Hierarchical Type-2 Fuzzy Logic Model to Improve Rapid Evaluation of Earthquake Hazard Safety of Existing Buildings. *In Structures*, V. 28.
- Harirchian, E., Lahmer, T., Buddhiraju, S., Mohammad, K., Mosavi, A., 2020, Earthquake Safety Assessment of Buildings Through Rapid Visual Screening, *Buildings*, 10(3), 51.
- Harirchian, E., Jadhav, K., Kumari, V., Lahmer, T., 2021, ML-EHSAPP: A Prototype For Machine Learning-Based Earthquake Hazard Safety Assessment Of Structures By Using A Smartphone App., *European Journal of Environmental and Civil Engineering*, 1-21.
- Harirchian, E., Hosseini, S. E. A., Jadhav, K., Kumari, V., Rasulzade, S., Işık, E., Wasif, M., Lahmer, T., 2021, A Review on Application of Soft Computing Techniques for the Rapid Visual Safety Evaluation and Damage Classification of Existing Buildings, *Journal of Building Engineering*, 102536.
- Harirchian, E., Kumari, V., Jadhav, K., Rasulzade, S., Lahmer, T., Raj Das, R., 2021, A Synthesized Study Based on Machine Learning Approaches for Rapid Classifying Earthquake Damage Grades to RC Buildings, *Applied Sciences*, 11, 7540.
- Harris, J., Reitherman, R., Rojahn, C., Whittaker, A., 2011, Comparison of U.S. and Chilean Building Code Requirements and Seismic Design Practice 1985–2010, *National Institute of Standards and Technology Engineering Laboratory*. Gaithersburg.
- Hassan, A. F., Sözen, M. A., Ocak 1997, Seismic Vulnerability Assessment of Low-Rise Building in Regions with Infrequent Earthquakes, *ACI Structural Journal*.

- He, K., Zhang, X., Ren, S., Sun, J., 2016, Deep Residual Learning for Image Recognition, *Paper Presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Huang, C., Zhai, K., Xie, X., Tan, J., 2021, Deep Residual Network Training For Reinforced Concrete Defects Intelligent Classifier, *European Journal of Environmental and Civil Engineering*, DOI: 10.1080/19648189.2021.2003250.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., Keutzer, K., 2016, Squeezenet: AlexNet-Level Accuracy with 50X Fewer Parameters and <0.5 MB Mobil Size, *arXiv:1602.07360v4 [cs.CV]*.
- Improvement of Nonlinear Static Seismic Analysis Procedures (FEMA 440), 2005, *Federal Emergency Management Agency*, Washington D.C., 392 s.
- Ioffe, S., Szegedy, C., 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *arXiv:1502.03167v3[cs.LG]*.
- Işık, E., Kutanis, M., 2013, Bitlis İlindeki Betonarme Binaların P25 Hızlı Tarama Yöntemi ile Değerlendirilmesi, *BAÜ Fen Bil. Enst. Dergisi*, Cilt 15(1) 21-29.
- Işık, E., Işık, M., Bülbül, M., 2018, Betonarme Binaların Web Tabanlı Hızlı Değerlendirilmesi, *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, Cilt 23, Sayı 1.
- İlki, A. Boduroğlu, H., Özdemir, P., Baysan, F., Demir, C., Şirin, S., 2003, Mevcut ve Güçlendirilmiş Yapılar için Sismik İndeks Yöntemi ve Yapısal Çözümleme Sonuçlarının Karşılaştırılması, 5. *Ulusal Deprem Mühendisliği Konferansı*, 61-62, İstanbul, Türkiye, 26-30 Mayıs.
- İlki, A., Comert, M., Demir, C., 2014, Performance Based Rapid Seismic Assessment Method (PERA) for Reinforced Concrete Frame Buildings, *Conference: 1st International Conference on Performance-based and Life-cycle Structural Engineering (PLSE)*, 5-7 Aralık 2012, Hong Kong. (Advances In Structural Engineering, Volume: 17 Issue: 3 Pages: 439-459 Published: 03/2014.)
- İnel, M., Bilgin, H., Özmen, H. B., Mayıs 2006, Mevcut Kamu Yapılarının Performans Değerlendirmesi, *TMH – Türkiye Mühendislik Haberleri/Sayı 444*.
- İnel, M., Bilgin, H., Özmen, H. B., Mart 2008, Orta Yükseklikli Betonarme Binaların Türkiye’de Yaşanan Son Depremlerdeki Performansı, *İMO Teknik Dergi*, İstanbul.
- Japan Building Disaster Prevention Association, 1990, Standart For Evaluation of Seismic Capacity of Existing Reinforced Concrete Buildings, Tokyo.
- Ji, M., Liu, L., Buchroithner, M., 2018, Identifying Collapsed Buildings Using Post-Earthquake Satellite Imagery And Convolutional Neural Networks: A Case Study Of The 2010 Haiti Earthquake, *Remote Sensing*, 10, 1689.
- Kang, J., Körner, M., Wang, Y., Taubenböck, H., Zhu, X. X., 2018, Building Instance Classification Using Street View Images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 145 (2018) 44-59.

- Kaplan, O., Güney, Y., Topçu, A., Özçelikörs, Y., Eylül 2017, A Rapid Seismic Safety Assessment Method for Mid-Rise Reinforced Concrete Buildings, *Bulletin of Earthquake Engineering*, 16, pages 889–915.
- Karaaslan, E., Bağcı, U., Çatbaş, F., 2018, Artificial Intelligence Assisted Infrastructure Assessment Using Mixed Reality Systems, *University of Central Florida*, 12800 Pegasus Drive, Orlando, Florida 32816.
- Karaçay, T., 2021, Derin Öğrenme ile Beton Yapılarda Otonom Çatlak Tespiti, *El-Cezerî Fen ve Mühendislik Dergisi*, Cilt: 9, No: 2, 2022 (607-624).
- Kassem, M. M., Nazri, F. M., Farsangi, E. N., 2020, The Seismic Vulnerability Assessment Methodologies: A State-of-the-Art Review, *Ain Shams Engineering Journal*, 11 (2020) 849–864.
- Keleşoğlu, M. K., Özturun, N. K., Çinicioğlu S. F., Bozbey, İ., Öztoprak, S., Özyazgan, C., Çelik, T., 2003, Deprem Risk Analizi: Bakırköy İlçesi Örneği, *Küçükçekmece ve Yakın Çevresi Teknik Kongresi, Deprem ve Planlaması*, Küçükçekmece Belediyesi.
- Kızrak, A., 2019, <https://medium.com/@ayyucekizrak/ölçeklendirme-ile-cnn-modelinin-doğruluk-ve-verimliliğini-artırma-efficientnet-cb6f2b6512de/> [Ziyaret Tarihi: 05.08.2020].
- Kim, B., Cho, S., 2020, Automated Multiple Concrete Damage Detection Using Instance Segmentation Deep Learning Model, *Applied Sciences*, 10, 8008; doi:10.3390/app10228008.
- Koyuncu, T., 2009, Mevcut Betonarme Binaların Deprem Yükleri Altında Performanslarının Hızlı Olarak Belirlenmesi için Yeni Bir Değerlendirme Yöntemi, Yüksek Lisans Tezi, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü*, Konya.
- Kömür, M., Altan, M., Pekgökgöz, R., K., 2007, FEMA-310 ile Betonarme Binaların Deprem Güvenliğinin Belirlenmesi, *KSÜ Fen ve Mühendislik Dergisi*, 10(1).
- Kumar, V., 2020, <https://analyticsindiamag.com/implementing-efficientnet-a-powerful-convolutional-neural-network/> [Ziyaret Tarihi: 31.07.2020].
- Kumari, V., Harirchian, E., Lahmer, T., Rasulzade, S., 2022, Evaluation of Machine Learning and Web-Based Process for Damage Score Estimation of Existing Buildings, *Buildings*, 12, 578.
- Kurt, F., 2018, Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı*, Ankara.
- Kutanis, M., Orak, E., Özcan, Z., Ekim 2007, Betonarme Binaların Performans Düzeylerinin Deprem Geçirmiş Binalarla İlişkilendirilerek Belirlenmesi, *Altuncu Ulusal Deprem Mühendisliği Konferansı*, İstanbul.
- Lauro, M. D., 2009, L'Aquila Earthquake, <https://www.marcodilauro.com/features/italy-earthquake/#pb-image-2176>.
- Lautour, O. R. D., Omenzetter, P., 2009, Prediction of Seismic-Induced Structural Damage Using Artificial Neural Networks, *Engineering Structures*, 31, 600- 606.

- Lee, S., Nevatia, R., 2004, Extraction and Integration of Window in a 3D Building Model from Ground View Images, *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'04)*, 1063-6919/04.
- Lei, B., Wang, N., Xu, P., Song, G., 2018, New Crack Detection Method for Bridge Inspection Using UAV Incorporating Image Processing, *Journal of Aerospace Engineering*, DOI: 10.1061/(asce)as.1943-5525.0000879.
- Liebold, F., Maas, H., 2016, Advanced Spatio-Temporal Filtering Techniques for Photogrammetric Image Sequence Analysis in Civil Engineering Material Testing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 111, 13–21.
- Lim, E., 2011, Concrete Buildings Damaged in Earthquake, A Collection of Case Studies, New Zealand.
- Liu, Y., Liao, Y., Zheng, N., 2012, Analysis of Strong Column and Weak Beam Behavior of Steel-Concrete Mixed Frames, 15 WCEE, Lisboa.
- Ma, H., Liu, Y., Ren, Y., Yu, J., 2020, Detection of Collapsed Buildings in Post-Earthquake Remote Sensing Images Based on the Improved YOLOv3, *Remote Sensing*, 12, 44.
- Maalek, R., Lichti, D., Ruwanpura, J., 2015, Development of an Automated 3D/4D As-Built Model Generation System for Construction Progress Monitoring and Quality Control, *5th International/11th Construction Specialty Conference*, Vancouver, British Columbia.
- Mahmoodzadeh, A., Mazaheri, M. M., 2008, A New Quantitative Method for The Rapid Evaluation of Buildings Against Earthquakes. Conference on Seismic Engineering, 8-11 Temmuz, 2008, Calabria, Italy. (2008 Seismic Engineering Conference Commemorating The 1908 Messina And Reggio Calabria Earthquake, Pts 1 And 2 Book Series: AIP Conference Proceedings Volume: 1020 Pages: 1755-1766 Part:1-2 Published: 2008)
- Malesa, M., Szczepanek, D., Kujawinska, M., Swiercz, A., Kolakowski, P., 2010, Monitoring of Civil Engineering Structures Using Digital Image Correlation Technique, *EPJ Web of Conferences* 6, 31014.
- Malkoçoğlu, A.B., 2020, Akut Lenfoblastik Lösemi Hücrelerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması, Yüksek Lisans Tezi, *Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü*, Samsun.
- Mishra, A., 2018, Metrics to Evaluate Your Machine Learning Algorithm, <https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234> [Ziyaret Tarihi: 09.08.2022].
- Mohamad, I., Yunus, M., Harith, N., 2019, Assessment of Building Vulnerability by Integrating Rapid Visual Screening and Geographic Information System: A Case Study of Ranau Township, *Materials Science and Engineering* 527, doi:10.1088/1757-899X/527/1/012042.
- Morfidis, K., Kostinakis, K., 2018, Approaches to the Rapid Seismic Damage Prediction of RC Buildings Using Artificial Neural Networks, *Engineering Structures*, 165, 120-141.
- Nabiyev, V., 2016, Yapay Zekâ- İnsan Bilgisayar Etkileşimi, Ankara: *Sözkesen Matbaacılık*.

- Nahata, D., Mulchandini, H., Bansal, S., Muthukumar, G., 2019, Post-Earthquake Assessment of Buildings Using Deep Learning, *Birla Institute of Technology & Science, Pilani, India*.
- NRRC (National Research Council of Canada), 1993, Manual for Screening of Buildings for Seismic Investigation, Canadian Standard, Ottawa: National Research Council of Canada.
- Oskouie, P., Gerber, B., Soibelman, L., 2015, A Data Quality-driven Framework for Asset Condition Assessment Using LiDAR and Image Data, *Journal of Computing in Civil Engineering*, DOI: 10.1061/9780784479247.030.
- Özer, E., 2007, Kapasite Tasarımı İlkesi ve Türk Deprem Yönetmeliği, *Altıncı Ulusal Deprem Mühendisliği Konferansı, İstanbul*.
- Özhendekci, N., Özhendekci, D., 2012, Rapid Seismic Vulnerability Assessment of Low- to Mid-Rise Reinforced Concrete Buildings Using Bingol's Regional Data, *Earthquake Spectra*, 28, 1165-1187.
- Özkaya, U., 2020, Derin Öğrenme Yöntemleri ile GPR B Tarama Görüntülerinin Analizi, Yüksek Lisans Tezi, *Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Konya*.
- Özmen, G., 2004, Çok Katlı Yapılarda Aşırı Burulma Düzensizliği, *İMO Teknik Dergi, İstanbul*.
- Özmen, H. B., İnel, M., Çaycı, B. T., 2011, Kapalı Çıkma Düzensizliğinin Betonarme Yapıların Sismik Davranışına Etkilerinin Değerlendirilmesi, *Yedinci Ulusal Deprem Mühendisliği Konferansı, İstanbul*.
- Öztürk, M., 2015, Field Reconnaissance of the October 23, 2011, Van, Turkey, Earthquake: Lessons from Structural Damages, *Journal of Performance of Constructed Facilities*, 29, 5.
- Öztürk, T., 2013, Binalarda Döşeme Boşluklarının Taşıyıcı Sistem Davranışına Etkisi, *İMO Teknik Dergi, İstanbul*.
- Pardalopoulos, S., Pantazopoulou, S., Lekidis, V., 2018, Simplified Method for Rapid Seismic Assessment of Older R.C. Buildings, *Engineering Structures*, 154, 10-22.
- Parmar, R., 2018, Common Loss functions in Machine Learning, <https://towardsdatascience.com/common-loss-functions-in-machine-learning-46af0ffc4d23> [Ziyaret Tarihi: 10.11.2019].
- Perez, H., Tah, J., Mosavi, A., 2019, Deep Learning for Detecting Building Defects Using Convolutional Neural Networks, *Sensors*, 19, 3556.
- Perrone, D., Aiello, M., Pecce, M., Rossi, F., 2015, Rapid Visual Screening for Seismic Evaluation of RC Hospital Buildings, *Structures*, doi: 10.1016/j.istruc., 03, 002.
- Pirim, H., 2011, Yapay Zekâ, *Journal of Yaşar University*, 81-93.
- Prestandart and Commentary for the Seismic Rehabilitation of Buildings (FEMA 356), 2000, *Federal Emergency Management Agency, Washington*, 518 s.

- Ramsundar, B., Zadeh, R. B., 2020, Tensorflow for Deep Learning, <http://www.oreilly.com/library/view/tensorflow-for-deep/9781491980446/ch04.html> [Ziyaret Tarihi: 04.04.2020].
- Rapid Visual Screening of Buildings for Potential Seismic Hazards, 1988, (FEMA 154-ATC 21): A handbook. Applied Technology Council, *Federal Emergency Management Agency*, Washington DC., 1988, 388 s.
- Rapid Visual Screening of Buildings for Potential Seismic Hazards, 1988, (FEMA 155-ATC 21-1): Supporting Documentation. Applied Technology Council. *Federal Emergency Management Agency*, Washington DC., 206 s.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A., 2016, You Only Look Once: Unified, Real-Time Object Detection, *IEEE Conference on Computer Vision and Pattern Recognition*, 779-788. doi: 10.1109/CVPR.2016.91.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A., 2016, You Only Look Once: Unified, Real-Time Object Detection, *IEEE Conference on Computer Vision and Pattern Recognition*, 779-788. doi: 10.1109/CVPR.2016.91.
- Rezaie, A., Achanta R., Godio, M., Beyer, K., 2020, Comparison of Crack Segmentation Using Digital Image Correlation Measurement and Deep Learning, *Construction and Building Materials*, 261 (2020) 120474.
- Riskli Yapıların Tespit Edilmesine İlişkin Esaslar Ek 2, 2019, *Çevre ve Şehircilik Bakanlığı*.
- Russell, S., Norvig, P., 2010, Artificial Intelligence: A Modern Approach (3rd ed.), *Upper Saddle River, New Jersey: Prentice Hal*.
- Seismic Evaluation and Retrofit of Concrete Buildings (ATC 40), 1996, *Applied Technology Council (ATC)*, Redwood City, California, 334 s.
- Sextos, A. G., Kappos, A. J., Stylianidis, K. C., 2008, Computer-Aided Pre- and Post- Earthquake Assessment of Buildings Involving Database Compilation, GIS Visualization, and Mobile Data Transmission, *Computer-Aided Civil and Infrastructure Engineering*, 23, 59–73.
- Sezen, H., Elwood, K. J., Whittaker, A. S., Mosalam, K. M., Wallace, J. W., Stanton, J. F., 2000, Structural Engineering Reconnaissance of the August 17, 1999, Kocaeli (Izmit), Turkey, Earthquake, *Pacific Earthquake Engineering Research Center*, PEER 2000/09 DEC.2000.
- Shahid, A., 2020, <https://towardsdatascience.com/efficientnet-scaling-of-convolutional-neural-networks-done-right-3fde32aef8ff/> [Ziyaret Tarihi: 05.08.2020].
- Shah, MF., Ahmed, A., Kegyes, G., Al-Ghamadi, A., Ray, RA., 2016, Case Study Using Rapid Visual Screening Method to Determine the Vulnerability of Buildings in Two Districts of Jeddah, Saudi Arabia. In: *15th International Symposium on New Technologies for Urban Safety of Mega Cities in Asia*, San Jose, Philippines.
- Shiga, T., Shibata, A., and Takahashi, T., 1968, Earthquake Damage and Wall Index of Reinforced Concrete Buildings. Proceedings of the Tohoku District Symposium, *Architectural Institute of Japan*, No. 12, December, pp. 29-32.

- Simonyan, K. ve Zisserman, A., 2014, Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv preprint arXiv:1409.1556.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014, Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, 15, 1929–1958.
- Sucuoğlu, H., Ekim 2007, Kentsel Yapı Stoklarında Deprem Risklerinin Sokaktan Tarama Yöntemi ile Belirlenmesi, *Altıncı Ulusal Deprem Mühendisliği Konferansı*, İstanbul.
- Szegedy, C., Liu, W., Jia, Y. Q., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015, Going Deeper with Convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z., 2016, Rethinking the Inception Architecture for Computer Vision, *CVPR*, 2818–2826.
- Tan, M., Le, Q., 2019, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, *Proceedings of the 36th International Conference on Machine Learning*, in PMLR 97:6105-6114.
- Temur, R., Öztörün, N. K., 2004, Yapıların Hızlı Durum Tespiti için Geliştirilen Uzman Bilgisayar Programı Durtes ile Genel Amaçlı Sonlu Elemanlarının Entegrasyonu, *İMO On Yedinci Teknik Kongre ve Sergisi*.
- Tezcan, S. S., Gürsoy, M. ve Kaya, E., Bal, İ. E., 2003, Depremde Can Kaybını Önleme Projesi, *1999 Kocaeli Acil Durum Konferansı*, İTÜ, İstanbul.
- Tezcan, S., Bal, İ. E., Özdemir, Z., Küçük, F., Eylül 2005, Depremde “Sıfır” Can Kaybı Nasıl Sağlanır?, *Şantiye İnşaat Makina ve Mimarlık Dergisi*, Sayı:232, Syf:108-112.
- Türk Bina Deprem Yönetmeliği, 2018, *Afet ve Acil Durum Yönetimi Başkanlığı*.
- Ünlü, R., Kiriş, R., 2022, Detection of Damaged Buildings After an Earthquake with Convolutional Neural Networks in conjunction with Image Segmentation, *The Visual and Computer*, 38, pages685–694 (2022).
- Üzen, H., Hanbay, K., 2022, <https://dergipark.org.tr/tr/download/article-file/742634> [Ziyaret Tarihi: 11.04.2022].
- Valentijn, T., Margutti, J., Homberg, M., Laaksonen, J., 2020, Multi-Hazard and Spatial Transferability of a CNN for Automated Building Damage Assessment, *Remote Sensing*, 2020, 12, 2839.
- Vashpanov, Y., Son, J., Heo, G., Podousova, T., Kim, Y., 2019, Determination of Geometric Parameters of Cracks in Concrete by Image Processing, *Advances in Civil Engineering*, Article ID 2398124, 14 pages.
- Verma, A., Qassim, H. ve Feinzimer, D., 2017, Residual Squeeze CNDS Deep Learning CNN Model for Very Large Scale Places Image Recognition, *2017 IEEE 8th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON)*, 463-470.

- Wang, C., Yu, Q., Law, K., McKenna, F., Yu, S., Tacirođlu, E., Zsarnoczay, A., Elhaddad, W., Çetiner, B., 2021, Machine Learning-based Regional Scale Intelligent Modeling of Building Information for Natural Hazard Risk Management, *Automation in Construction*, DOI: 10.1016/j.autcon.2020.103474.
- Wen, X., Bi, X., Xiang, W., 2022, Rapid Seismic Response Prediction of RC Frames based on Deep Learning and Limited Building Information, *Engineering Structures*, 267, 114638.
- Wen, W., Zhang, C., Zhai, C., 2015, Object-Oriented Collapsed Building Extraction From Multi-Source Remote Sensing Imagery Based On SVM, North China Earthquake, *Science*, 33, 13–19.
- Yakut, A., Erberik, A., Akkar, S., Sucuođlu, H., İlki, A., February 2012, Rapid Seismic Assessment Procedures for Turkish Building Stock, Seismic Engineering Research Infrastructures for European Synergies, *Series Workshop Role of Research Infrastructures in Seismic Rehabilitation*, İstanbul.
- Yetkin, M., 2014, Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniđiyle Optimizasyonu, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Gemi ve Deniz Teknolojisi Mühendisliđi*, İstanbul.
- Yoshitake, I., Maeda, T., Hieda, M., 2018, Image Analysis for the Detection and Quantification of Concrete Bugholes in a Tunnel Lining, *Case Studies in Construction and Materials* 8, 116-130.
- Yön, B., Sayın, E., 2008, Kısa Kolon Teşkilinin Yapı Hasarlarına Etkisi, *Fen Bilimleri Enstitüsü Dergisi*, ISSN1012-2354 Erciyes Üniversitesi, Elâzığ.
- Yu, Q., Wang, C., Law, K., McKenna, F., Yu, S., Tacirođlu, E., Çetiner, B., 2020, Building Information Modeling and Classification by Visual Learning at A City Scale, *Chaofeng Wang*.
- Yu, Q., Wang, C., Law, K., McKenna, F., Yu, S., Tacirođlu, E., Zsarnoczay, A., Çetiner, B., 2020, Rapid Visual Screening of Soft-Story Buildings from Street View Images Using Deep Learning Classification, *Earthquake Engineering and Engineering Vibration*, DOI: 10.1007/s11803-020-0598-2.
- Yüksel, İ., 2008, Betonarme Binaların Deprem Sonrası Acil Hasar Deđerlendirmeleri, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 24 (1-2) 260 – 276.
- Zhang, Z., Wei, H., Yum, S., Chen, J., 2019, Automatic Object-Detection of School Building Elements in Visual Data: A Gray-Level Histogram Statistical Feature-Based Method, *Applied Sciences*, 9, 3915; doi:10.3390/app9183915.
- Zhang, Z., Zhou, X., Lin, M., Sun, J., 2017, Development of a Data-Mining Technique for Regional-Scale Evaluation of Building Seismic Vulnerability, *Applied Sciences*, 9, 1502; doi:10.3390/app9071502.
- Zhang, X., Hsu, T., Wei, H., Chen, J., 2019, An Extremely Efficient Convolutional Neural Network for Mobile Devices, *arXiv:1707.01083v2 [cs.CV]*.
- Zhao, Y., Ren, H., Cao, D., 22–27 July 2018, The Research Of Building Earthquake Damage Object-Oriented Change Detection Based On Ensemble Classifier With Remote Sensing Image, *In*

Proceedings of the IEEE International Geoscience and Remote Sensing Symposium-IGARSS, Valencia, Spain, pp. 4950–4953.

Zhu, Z., Brilakis, I., 2010, Improvements to Concrete Column Detection in Live Video, Georgia Institute Of Technology, Atlanta, USA, *27th International Symposium on Automation and Robotics in Construction (ISARC 2010)*.

Zhu, Z., Brilakis, I., 2010, Concrete Column Recognition in Images and Videos, *Journal of Computing in Civil Engineering*, DOI: 10.1061/_ASCE_CP.1943-5487.0000053.

Zoph, B., Vasudevan, V., Shlens, J., Le, Q. V., 2018, Learning Transferable Architectures for Scalable Image Recognition, arXiv:1707.07012v4 [cs.CV].

<https://seyler.eksisozluk.com/deprem-aninda-gerceklesen-en-kotu-durumlardan-biri-zemin-sivilasmasi> [Ziyaret Tarihi: 12.04.2022].

<https://www.yalovagazetesi.com/ulusal/yalova-zorunlu-konut-sigortasinda-ikinci-sirada-h10493.html> [Ziyaret Tarihi: 12.04.2022].

<https://www.cnnturk.com/2010/turkiye/02/24/boyle.bir.bina.hic.gorulmedi/565062.0/index.html> [Ziyaret Tarihi: 12.04.2022].

https://production-media.paperswithcode.com/methods/Screen_Shot_2020-06-26_at_6.04.32_PM.png [Ziyaret Tarihi: 11.04.2022].

https://www.researchgate.net/figure/Xception-CNN-architecture-for-the-detection-and-classification-of-powder-bed-defects-at_fig3_350319854 [Ziyaret Tarihi: 11.04.2022].

<https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasina-matematiksel-yaklasim/> [Ziyaret Tarihi: 11.04.2022].

<https://www.diken.com.tr/izmirde-acil-yikilmesi-gereken-342-bina-var/> [Ziyaret Tarihi: 12.06.2022].

<https://deprem.afad.gov.tr/deprem-tehlike-haritasi> [Ziyaret Tarihi: 12.07.2022].

<https://www.gorgoda.com/sinir-hucresi-noron.html> [Ziyaret Tarihi: 09.08.2022].