



**KTO KARATAY ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI  
TEZLİ YÜKSEK LİSANS PROGRAMI**

**DERİN ÖĞRENME SINIFLANDIRICILARI KULLANARAK BİNA CEPHE  
GÖRÜNTÜLERİNİN HIZLI GÖRSEL TARAMA ANALİZİ**

**Fuat YALINIZ**

**Yüksek Lisans Tezi**

**KONYA  
Ağustos 2022**

DERİN ÖĞRENME SINIFLANDIRICILARI KULLANARAK BİNA CEPHE  
GÖRÜNTÜLERİNİN HIZLI GÖRSEL TARAMA ANALİZİ

Fuat YALINIZ

KTO Karatay Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Mekatronik Mühendisliği Anabilim Dalı  
Tezli Yüksek Lisans Programı

Yüksek Lisans Tezi

Tez Danışmanı: Dr. Öğr. Üyesi Amir YAVARIABDI  
İkinci Danışman: Prof. Dr. Musa Hakan ARSLAN

Konya  
Ağustos 2022

## BİLDİRİM

Enstitü tarafından onaylanan Yüksek Lisans/Doktora tezimin tamamını veya herhangi bir kısmını basılı veya dijital biçimde arşivleme ve aşağıda belirtilen koşullar dahilinde erişime açma iznini KTO Karatay Üniversitesine verdiğimi bildiririm. Bu izinle, Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak ve gelecekteki çalışmalar (makale, kitap, lisans, patent vb.) için tezimin tamamının veya bir bölümünün kullanım hakları yalnızca bana ait olacaktır.

Tezimin bütünüyle kendi çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Telif hakkı bulunan ve sahiplerinden yazılı izinle kullanılması zorunlu olan kaynakları, yazılı izin alarak kullandığımı ve istenildiğinde izinlerin suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayımlanan “Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge” kapsamında, tezim, aşağıda belirtilen koşullar haricince, YÖK Ulusal Tez Merkezi ve KTO Karatay Üniversitesi Açık Erişim Sisteminde erişime açılır.

Enstitü / Fakülte Yönetim Kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.<sup>1</sup>

Enstitü / Fakülte Yönetim Kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ... ay ertelenmiştir.<sup>2</sup>

Tezimle ilgili gizlilik kararı verilmiştir.<sup>34</sup>

29 Ağustos 2022

---

**Fuat YALINIZ**

---

<sup>1</sup> MADDE 6(1) Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.

<sup>2</sup> MADDE 6(2) Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulunun gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.

<sup>3</sup> MADDE 7(1) Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, tezin yapıldığı kurum tarafından verilir. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, ilgili kurum ve kuruluşun önerisi ile enstitü veya fakültenin uygun görüşü üzerine üniversite yönetim kurulu tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.

<sup>4</sup> MADDE 7(2) Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

## ETİK BEYAN

KTO Karatay Üniversitesi Lisansüstü Eğitim Enstitüsü Tez/Proje Hazırlama ve Yazım Kurallarına uygun olarak Dr. Öğr. Üyesi Amir YAVARIABDI danışmanlığında tarafımdan üretilen bu tez çalışmasında; sunduğum tüm veri, enformasyon, bilgi ve belgeleri bilimsel etik kuralları çerçevesinde elde ettiğimi, tüm değerlendirme, analiz, bulgu ve sonuçları bilimsel usullere uygun olarak sunduğumu, tez çalışmasında yararlandığım kaynakların tümüne bilimsel normlara uygun biçimde atıfta bulunarak kaynak gösterdiğimi, tezimin kaynak gösterilen durumlar dışında özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

29 AĞUSTOS 2022

---

**Fuat YALINIZ**

## TEŐEKKÜR

Çalıőmalarım süresince her türlü yardımına koőan ve özellikle yapay zekâ konusundaki tecrübeler ile yardımcı olan tez danıőmanım Dr. Öğr. Üyesi Amir YAVARIABDI'ye, hızlı deęerlendirme yöntemlerindeki tecrübesi ile yardımlarımı esirgemeyen ikinci tez danıőmanım Prof. Dr. Musa Hakan ARSLAN hocama ve veri toplama sürecinde yardımcı olan Muhammet Yuőa EKİCİ, Fatih Mehmet AŐIK ve Selim ÇELİK'e teőekkürü borç bilirim.

29 Aęustos 2022

Fuat YALINIZ

## ÖZET

Fuat YALINIZ

Derin Öğrenme Sınıflandırıcıları Kullanarak Bina Cephe Görüntülerinin Hızlı Görsel

Tarama Analizi

Yüksek Lisans Tezi

Konya, 2022

Türkiye ve dünyada binaların deprem öncesi risk durumlarının hızlı bir şekilde belirlenebilmesi için farklı yöntemler kullanılmaktadır. Bu yöntemlerden en fazla kabul görmüş olanı, bina cephesine bağlı olarak yapılan hızlı görsel tarama yöntemidir. Bu yöntemde binaların risk öncelik durumu, dış cephe görüntüsü ve bölgesel depremsellik parametreleri kullanılarak hesaplanır. Binanın başlangıç puanından, binanın özellikle deprem performansını olumsuz yönde etkileyecek olan geometrik ve mekanik özelliklerinden aldığı ceza puanları çıkartılarak binanın nihai risk öncelik skoru bulunur. Binanın ceza puanlarının bulunmasında, binanın bitişik nizam olup olmadığı, yapısal düzensizlikler, kısa kolon oluşumu, geometrik düzensizlikler, zemin eğimi, ağır çıkma, asma kat durumu vs. gibi pek çok etmenin değerlendirilmesi gerekmektedir. Bu ceza puanlarının da tespiti sonucunda elde edilen nihai skorlar ile, söz konusu yapısal envanter içinde değerlendirilmesi yapılan binaların deprem risk durumuna göre öncelikleri tespit edilir. Deprem riski fazla olan pek çok ülkede kullanılan bu hızlı değerlendirme yöntemlerinin kullanımında ana problem bina yapı stokunun çok büyük olmasından dolayı, tüm binaların değerlendirilmesi çok fazla zaman ve insan kaynağına ihtiyaç duyulmasıdır. Bu sorunları ve insan hatalarını minimize etmek için yapay zekâ tabanlı bina cephe görüntülerini analiz eden sistemlerin geliştirilmesi oldukça önemli bir konudur. Bu tezde, hızlı görsel tarama yöntemlerinde kullanılan deprem davranışına etki ettiği bilinen iki ana parametre olan “binalarda çarpışma durumu” ve “ağır çıkma” etkilerinin bina cephe görseli üzerinden tespit edilebilen (çıkartılabilen) bir algoritma geliştirilmiştir. Çalışmada makine öğrenme yöntemlerinden biri olan, derin öğrenme yöntemi kullanılmıştır. İki ayrı sınıflandırma gerçekleştirilmiştir. Sınıflandırmalar ikili sınıflardan oluşmaktadır. Her bir sınıf yaklaşık 2500 bina cephe görselinden oluşmaktadır. Çalışmada toplamda 10000 adet bina cephe görüntüsü kullanılmıştır. Derin öğrenme metodu olarak ise KSA (Konvolüsyonel Sinir Ağları) kullanılmıştır. Tezin temel amacı VGG19, SqueezeNet ve DarkNet53 KSA modellerini kullanarak bina cephe görüntülerinden, binaların deprem performansında etkili olduğu bilinen iki farklı parametrenin uzmana gerek kalmadan cephe görselleri ile derin öğrenme yöntemleri kullanılarak otomatik olarak elde edebilmektir. Bitişik nizam binaların sınıflandırılmasında en iyi başarıyı (96.68%) DarkNet53 göstermiştir. Ağır çıkma binaların sınıflandırılmasında en iyi başarıyı (88.62%) DarkNet53 göstermiştir.

### Anahtar Kelimeler

Deprem riski, derin öğrenme, evrişimsel sinir ağları, hızlı görsel tarama, KSA

## ABSTRACT

Fuat YALINIZ

Fast visual analysis of building facade images using deep learning classifier for rapid  
visual screening  
Master's Thesis  
Konya, 2022

Different methods are used in order to quickly determine the pre-earthquake risk status of buildings in Turkey and in the world. The most widely accepted of these methods is the rapid visual scanning method based on the facade of the building. In this method, the risk priority status of the buildings is calculated using the exterior view and regional seismicity parameters. The final risk priority score of the building is found by subtracting the penalty points received from the building's initial score, especially from the geometric and mechanical properties that will adversely affect the seismic performance of the building. In finding the penalty points of the building, whether the building is adjacent or not, structural irregularities, short column formation, geometric irregularities, ground slope, heavy overhang, mezzanine status etc. Many factors need to be evaluated, such as With the final scores obtained as a result of the determination of these penalty points, the priorities of the buildings evaluated within the said structural inventory are determined according to the earthquake risk status. The main problem in the use of these rapid assessment methods, which are used in many countries with a high earthquake risk, is that the evaluation of all buildings requires a lot of time and human resources due to the very large building stock. In order to minimize these problems and human errors, it is very important to develop systems that analyze artificial intelligence-based building facade images. In this thesis, an algorithm has been developed that can detect (subtract) the effects of "collision status in buildings" and "heavy overhang", which are two main parameters known to affect earthquake behavior used in rapid visual scanning methods, from the building facade image. Deep learning method, which is one of the machine learning methods, was used in the study. The dataset consisting of building facade images consists of 4 classes, each of which contains approximately 2500 images. A total of 10000 building facade images were used in the study. CNN (Convolutional Neural Networks) was used as a deep learning method. The main purpose of the thesis is to automatically obtain two different parameters known to be effective in earthquake performance of buildings from building facade images using VGG19, SqueezeNet and DarkNet53 CNN models, without the need for an expert, by using facade images and deep learning methods. DarkNet53 showed the best performance (96.68%) in the classification of adjacent buildings. DarkNet53 showed the best performance (88.62%) in the classification of heavy overhanging buildings.

### Keywords

CNN, convolutional neural network, deep learning, earthquake risk, rapid visual screening (RVS)

## İÇİNDEKİLER

KABUL VE ONAY .....	i
BİLDİRİM .....	ii
ETİK BEYAN.....	iii
TEŞEKKÜR.....	iv
ÖZET.....	iv
ABSTRACT.....	v
İÇİNDEKİLER .....	vi
TABLolar DİZİNİ .....	viii
ŞEKİLLER DİZİNİ.....	ix
SİMGELER DİZİNİ.....	xi
KISALTMALAR DİZİNİ.....	xii
1. GİRİŞ .....	1
2. LİTERATÜR .....	6
3. KURAMSAL TEMELLER .....	10
3.1. Hızlı Değerlendirme Yöntemleri.....	10
3.1.1. Hızlı Değerlendirme Yöntemi Parametreleri.....	11
3.1.2. Sokak Taraması Yöntemleri (1. Kademe Yöntemler).....	17
3.2. Derin Öğrenme .....	20
3.2.1. Konvolüsyonel Sinir Ağları.....	21
3.2.2. Konvolüsyonel Sinir Ağı Modelleri .....	25
4. VERİ SETİ VE METODOLOJİ .....	29
4.1. Veri Seti.....	29
4.2. Metotlar .....	32
4.2.1. Bitişik Nizam Binaların Sınıflandırılması .....	33
4.2.2. Ağır Çıkma Binaların Sınıflandırılması.....	37
4.2.3. Sınıflandırma Metrikleri .....	39
4.2.4. Grad-CAM ile Isı Haritasının Oluşturulması .....	41
5. BULGULAR VE TARTIŞMA .....	43
5.1. Bitişik Nizam Binaların Sınıflandırma Sonuçları .....	43
5.1.1. Bitişik Nizam Binaların VGG19 Eğitim Sonuçları .....	43
5.1.2. Bitişik Nizam Binaların DarkNet53 Eğitim Sonuçları.....	45
5.1.3. Bitişik Nizam Binaların SqueezeNet Eğitim Sonuçları.....	48



5.2. Ağır Çıkma Binaların Sınıflandırma Sonuçları.....	51
5.2.1. Ağır Çıkma Binaların VGG19 Eğitim Sonuçları .....	51
5.2.2. Ağır Çıkma Binaların DarkNet53 Eğitim Sonuçları .....	53
5.2.3. Ağır Çıkma Binaların SqueezeNet Eğitim Sonuçları .....	55
5.3. Sonuçların Karşılaştırılması .....	57
6. SONUÇ .....	61
KAYNAKLAR .....	63
ÖZGEÇMİŞ .....	67
EK 1. FEMA 154 BİNA DEĞERLENDİRME FORMU .....	68
EK 2. SQUEEZENET AĞ YAPISI .....	69
EK 3. DARKNET AĞ YAPISI.....	72

## TABLolar DİZİNİ

Tablo 1. FEMA 154 bina türleri.....	18
Tablo 2. FEMA 154 Olumsuzluk parametreleri .....	18
Tablo 3. FEMA 154 Deprem tehlike bölgeleri .....	19
Tablo 4. FEMA 154 Taban ve yapısal sistem puan tablosu.....	20
Tablo 5. Olumsuzluk parametre puanları.....	20
Tablo 6. VGGNet mimarisi parametreleri ve katmanları.....	26
Tablo 7. DarkNet53 mimarisi parametreleri ve katmanları .....	27
Tablo 8. Bitişik nizam veri seti dengeli ve dengesiz veri adetleri .....	31
Tablo 9. Ağır çıkma veri seti dengeli ve dengesiz veri adetleri.....	31
Tablo 10. Donanım özellikleri .....	32
Tablo 11. VGG19 katmanları ve parametreleri.....	34
Tablo 12. Bitişik nizam VGG19 eğitim parametreleri.....	35
Tablo 13. Bitişik nizam DarkNet eğitim parametreleri.....	36
Tablo 14. Bitişik nizam SqueezeNet eğitim parametreleri .....	37
Tablo 15. Ağır çıkma VGG19 eğitim parametreleri .....	38
Tablo 16. Ağır çıkma DarkNet53 eğitim parametreleri.....	38
Tablo 17. Ağır çıkma SqueezeNet eğitim parametreleri.....	39
Tablo 18. Ağır çıkma bina için hata matrisi.....	40
Tablo 19. Bitişik nizam VGG19 eğitim sonuçları .....	43
Tablo 20. Bitişik nizam DarkNet53 eğitim parametreleri.....	46
Tablo 21. Bitişik nizam SqueezeNet eğitim sonuçları .....	49
Tablo 22. Ağır çıkma VGG19 eğitim sonuçları.....	51
Tablo 23. Ağır çıkma DarkNet53 eğitim sonuçları.....	53
Tablo 24. Ağır çıkma SqueezeNet eğitim sonuçları .....	56
Tablo 25. Ağır çıkma KSA modelleri doğruluk oranı karşılaştırması.....	59
Tablo 26. Bitişik nizam KSA modelleri doğruluk oranı karşılaştırması.....	59

## ŞEKİLLER DİZİNİ

Şekil 1. Hızlı değerlendirme yöntemi akış şeması .....	10
Şekil 2. (a):Tek cepheden bitişik nizam bina cephe görüntüsü. (b):İki cepheden bitişik nizam bina cephe görüntüsü. (c):Tek cepheden bitişik nizam bina cephe görüntüsü. ....	11
Şekil 3. (a):Bitişik nizam olmayan bina cephe görüntüsü. (b): Bitişik nizam olmayan bina cephe görüntüsü.....	12
Şekil 4. Yapısal sistem türü.....	12
Şekil 5. Serbest kat adetleri. (a):6 katlı bina. (b):6 katlı bina. (c):5 katlı bina. (d):5 katlı bina. (e):5 katlı bina. ....	13
Şekil 6. Çerçeve süreksizliği örnek bina .....	14
Şekil 7. (a):Ağır çıkma bina. (b):Depremde hasar almış ağır çıkma bina.....	15
Şekil 8. Yumuşak kat örneği. (a):Yumuşak kat olmayan bina. (b):Yumuşak kat olan bina.....	16
Şekil 9. Konvolüsyonel sinir ağı yapısı .....	21
Şekil 10. Örnek konvolüsyon işlemi .....	22
Şekil 11. Maksimum havuzlama örneği.....	23
Şekil 12. Düzleştirilmiş doğrusal birim işlem örneği. (a): Düzleştirilmiş doğrusal birime giren (4x4) matris. (b): Düzleştirilmiş doğrusal birimde işlem görün matrisin çıktısı. ..	24
Şekil 13. Düzleştirilmiş doğrusal birim (ReLU) aktivasyon fonksiyonu grafiği.....	24
Şekil 14. Sigmoid aktivasyon fonksiyonu grafiği .....	25
Şekil 15. SqueezeNet katman yapısı .....	28
Şekil 16. Bitişik nizam durumu olan binalar. (a): 3 katlı tek cepheden bitişik nizam bina. (b): 4 katlı tek cepheden bitişik nizam bina. (c) 2 katlı iki cepheden bitişik nizam bina. ....	29
Şekil 17. Bitişik nizam durumu aynalama ve gürültü eklenerek veri artırılması. (a):Ham bitişik bina görseli. (b): Aynalanmış bitişik nizam bina görseli. (c):Gürültü eklenmiş aynalanmış bitişik bina görseli.....	30
Şekil 18. Ağır çıkma binalar. (a): 5 katlı ağır çıkma bina. (b): 3 katlı ağır çıkma bina. (c): 4 katlı ağır çıkma bina. ....	30
Şekil 19. Bitişik nizam ve ağır çıkma bina sınıflandırma akış diyagramı .....	32
Şekil 20. Isı haritası renk barı .....	42
Şekil 21. Bitişik nizam VGG19 eğitim süreci.....	43
Şekil 22. Bitişik nizam VGG19 test görüntüleri .....	44
Şekil 23. Bitişik nizam DarkNet53 eğitim süreci.....	45
Şekil 24. Bitişik nizam DarkNet53 test görüntüleri.....	47
Şekil 25. Bitişik nizam SqueezeNet eğitim süreci .....	48

Şekil 26. Bitişik nizam SqueezeNet test görüntüleri.....	50
Şekil 27. Ağır çıkma VGG19 eğitim süreci .....	51
Şekil 28. Ağır çıkma VGG19 test görüntüleri .....	52
Şekil 29. Ağır çıkma DarkNet53 eğitim süreci .....	53
Şekil 30. Ağır çıkma DarkNet53 test görüntüleri .....	54
Şekil 31. Ağır çıkma SqueezeNet eğitim süreci.....	55
Şekil 32. Ağır çıkma SqueezeNet test görüntüleri .....	57
Şekil 33. Ağır çıkma test sonuçları karşılaştırma.....	58
Şekil 34. Bitişik nizam test sonuçları karşılaştırma .....	60

## SİMGELER DİZİNİ

<b>Simge</b>	<b>Açıklama</b>
$n_{sk}$	Serbest kat adedi
$\sum$	Toplam sembolü
$y^{\text{logit}}$	Softmax öncesi sınıf puanı
$F^n$	Öznetelik haritası, n adet
$Y$	Yükseklik
$G$	Genişlik
ReLU	Doğrusal lineer birim

## KISALTMALAR DİZİNİ

<b>Kısaltma</b>	<b>Açıklama</b>
BAÇ	Betonarme Çerçeve
CNN	Convolutional Neural Networks
DDB	Düzleştirilmiş Doğrusal Birim
FEMA	Federal Emergency Management Agency
GPU	Graphics Processing Unit
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
KSA	Konvolüsyonel Sinir Ağı
RBTEİE	Riskli Binaların Tespit Edilmesine İlişkin Esaslar
ReLU	Rectified Linear Unit
RGB	Red Green Blue
SDDB	Sızıntı Düzleştirilmiş Doğrusal Birim
TBDY	Türkiye Bina Deprem Yönetmeliği
YOLO	You Only Look Once
YSA	Yapay Sinir Ağı

## 1. GİRİŞ

Türkiye dünyanın en etkin deprem kuşaklarından birinin üzerinde bulunmaktadır. Türkiye’de geçmişte yapıların ağır hasar aldığı ve toptan yıkıldığı depremler olmuştur. Her ne kadar son yıllarda yapısal kalite artsa da mevcut yapı stokunun halen önemli bir kısmı (%45 civarı) deprem açısından yeterli seviyede değildir. Bu nedenle Türkiye’de gelecekte de oluşacak orta-büyük depremlerde maalesef büyük can ve mal kaybının yaşanması ihtimali oldukça yüksektir. Her ne kadar binaların yapıldıkları yıl itibari ile yürürlükte olan deprem yönetmelikleri depremlerde oluşabilecek yıkımların önlenmesi açısından oldukça katı kurallara sahip olsa da Türkiye’de gerçekleşen depremlerde oluşan büyük yıkımların sebebi, özellikle betonarme binalarda doğru malzeme kullanılmaması, yapım tekniklerinin yetersiz ve yanlış olması, deprem mühendisliği ilkelerine göre yapıların iyi tasarlanmaması, kalite denetiminin yetersizliği vb. gibi pek çok faktöre bağlıdır.

Türkiye’de depremlerin ardından en çok hasar göre yapı türü betonarme binalardır. Bunun nedeni çelik, ahşap gibi malzemelere nazaran betonarmenin daha ekonomik olması ve imalatının nispeten daha kolay yapılabilmesidir. Ayrıca yüksek nüfus oranlarının bulunduğu bölgelerde yüksek katlı bina isteği de betonarmeyi diğer taşıyıcı sistem türlerine göre daha popüler hale getirmiştir. Fakat Türkiye’de bulunan betonarme binaların yaklaşık %30-%45’lik kısmı 1998 ve öncesinde inşa edilmiştir (Gürbüz & Tekin, 2017). 1998 yılı Türk yapı stoku için bir milat olarak kabul edilmektedir. Bunun temel nedeni 1998 yılında değişen oldukça kapsamlı bir hale gelerek değişen deprem yönetmeliği ve 17 Ağustos 1999’da Adapazarı’nda meydana gelen Büyük Marmara depreminin ( $M_w=7.4$ ) oluşturduğu toplumsal farkındalıktır.

Yeryüzünü oluşturan plakaları birbirinden ayıran fayların birbirlerine göre yapmış oldukları rölatif hareketler neticesinde meydana gelen depremlerin oluşumunun önceden tahmini ve deprem oluşumunun geciktirilmesi ya da önlenmesi mümkün olmadığı için, ancak mevcut yapı stokunun depreme karşı dayanıklı hale getirilmesi hayati önem arz etmektedir. Bu nedenle deprem açısından riskli binaların hızlı bir şekilde tespit edilip, depreme hazır hale getirilmesi son derece hayati bir konudur.

Deprem riski altında bulunan bölgelerdeki sayıları yüzbinler ile ifade edilen tüm binaların, deprem hasar riskini belirlemek ekonomik faktörler ve zaman açısından

zordur. Zira gerçek deprem performansının tespit edilebilmesi için saha çalışmaları ile elde edilen veriler ve modellemekle beraber haftalar süren bir binanın detaylı sismik analizi yerine, binaları deprem risk öncelik seviyelerine göre sıralayarak çok riskli olan binaların tespit edilmesi zaman ve en önemlisi ekonomi açısından oldukça önemlidir.

Binaların depreme dayanıklılık ve öncelik durumlarının kısa sürede belirlenmesi için hızlı değerlendirme yöntemleri geliştirilmiştir (Bal, Tezcan, & Gülay, 2007). Bu yöntemde binaların risk öncelik durumu, dış cephe görüntüsü ve bölgesel deprensellik parametreleri kullanılarak hesaplanır. Bu yöntemlerde binanın bulunduğu yerel zemin durumu, bölgenin deprenselliği, binanın yaşı, kat sayısı vb. gibi pek çok parametreye bağlı olarak binaya bir başlangıç puanı verilir. Binanın başlangıç puanından, binanın özellikle deprem performansını olumsuz yönde etkileyecek olan geometrik ve mekanik özelliklerinden aldığı ceza puanları çıkartılarak binanın nihai risk öncelik skoru bulunur. Binanın ceza puanlarının bulunmasında, binanın bitişik nizam olup olmadığı, yapısal düzensizlikler, kısa kolon oluşumu, geometrik düzensizlikler, zemin eğimi, ağır çıkma, asma kat durumu, zemin katta (kritik katta) dolgu duvar bulunması, zemin katta kolon ve perde kesit alanları ve doğrultuları vs. gibi pek çok etmenin değerlendirilmesi gerekmektedir. Bu ceza puanlarının da tespiti sonucunda elde edilen nihai skorlar ile, söz konusu yapısal envanter içinde değerlendirilmesi yapılan binaların deprem risk durumuna göre öncelikleri tespit edilir. Deprem riski fazla olan pek çok ülkede kullanılan bu hızlı değerlendirme yöntemlerinin kullanımında ana problem bina yapı stokunun çok büyük olmasından dolayı, tüm binaların değerlendirilmesi çok fazla zaman ve insan kaynağına ihtiyaç duyulmasıdır. Özellikle değerlendirmelerde genellikle yapı-deprem bilimi tecrübesi olan uzmanlar görev alsın da çok büyük veri gerektiren analizlerde sayıca çok fazla ve tecrübe olarak da farklı seviyelerde yer alan mühendisler (uzmanlar) görev alabilmektedir. Bu durum her uzmanın ilgili parametreler konusunda yaklaşımı farklı olmasına ve değerlendirmelerde elde edilen nihai skorların farklılaşmasına neden olmaktadır. Bu sorunları ve insan hatalarını minimize etmek için yapay zekâ tabanlı bina cephe görüntülerini analiz eden sistemlerin geliştirilmesi oldukça önemli bir konudur.

Hızlı değerlendirme yöntemlerinde binaların deprem davranışına etkin çok sayıda parametre bulunmaktadır. Bunlar binanın yapım türü, yılı, kat sayısı, yumuşak kat ve zayıf kat etkileri, kısa kolon oluşma potansiyeli, ağır çıkmaların varlığı, eğimli



topoğrafyanın etkisi, bitişik nizam, binalarda olası çarpışma durumu, bina cephesinin görünür bina kalitesi vb. gibi özetlenebilir. Bu parametreler kullanılarak, binanın detaylı sismik performans analizi yapılması için öncelik durumunu gösteren puanlama yapılır. Çıkan sonuca göre yapılar gruplandırılarak deprem açısından binaların müdahale önceliği tespit edilir. Hızlı değerlendirme yöntemlerinden en çok kabul görmüş olan yöntem Hızlı Görsel Tarama (Rapid Visual Screening-RVS) yöntemidir. Literatürde geliştirilen RVS yöntemi ile sahadaki uzman mühendis bina cephesi üzerinden puanlama yaparak risk durumunu belirlemektedirler (FEMA 154, 2015).

Bu tezde, hızlı görsel tarama yöntemlerinde kullanılan deprem davranışına etki ettiği bilinen iki ana parametre olan “binalarda çarpışma durumu” ve “ağır çıkma” etkilerinin bina cephe görseli üzerinden tespit edilebilen (çıkılabilen) bir algoritma geliştirilmiştir. Bu motivasyonlar, çalışmada derin öğrenme sınıflandırıcıları kullanarak, depremde hasar görebilirlik riskinin hesaplanması için, sahada yapılacak olan iş yükünün kaldırılması, tespit süresi ve işlem maliyetinin azaltılmasını amaçlanarak, deprem riskinin belirlenmesinde önemli olan iki adet kritik parametrenin (çarpışma ve ağır çıkma) tespitinin, yapıların dış cephe görüntüleri kullanılarak sahaya gidilmeden analiz edilip edilemeyeceği sorgulanmıştır.

Yapılan kapsamlı literatür araştırılmasına göre hızlı değerlendirme yöntemlerinde kullanılan bitişik nizam ve ağır çıkma durumunun, herhangi bir algoritma kullanarak cephe görüntüleri üzerinden otomatik tespitinin sağlanması üzerine yapılmış bir çalışma bulunmamaktadır. Bu açıdan tez konusunun henüz çalışılmamış bir alan üzerinde olması da önemlidir.

Yukarıda özetlenen ana araştırma çerçevesinden yola çıkarak, bu tez çalışmasında hızlı değerlendirme yönteminde kullanılan parametrelerden, yapının bitişik nizam olup olmama ve ağır çıkma olup olmama durumu derin öğrenme sınıflandırıcıları kullanılarak otomatik olarak tespit edilip sınıflandırılması amaçlanmaktadır. Bu amaç doğrultusunda derin öğrenme algoritmalarından Konvolüsyonel Sinir Ağları (KSA) kullanılmıştır. Google Haritalar Sokak Görünümü kullanılarak bina cephe görüntüleri toplanmıştır. Toplanan cephe görüntüleri bitişik nizam, bitişik nizam olmayan, ağır çıkma ve ağır çıkma olmayan bina cephe görüntülerinden oluşmaktadır. Oluşturulan veri setlerinden elde edilen eğitim ve test dosyaları kullanılarak kendini ispatlamış ön

eđitimli KSA modellerinin eđitimleri ve testleri gerekleřtirilmiřtir. Derin renme KSA modellerinden VGG19 (Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016), SqueezeNet (Iandola et al., 2016) ve DarkNet53 (Geng, Ma, & Huang, 2020) modelleri kullanılarak alıřmanın 10000 adet bina grseli kullanılmıřtır. Her bir sınıfı 2500 adet grntden 4 adet sınıf oluřturulmuřtur. Bu sınıflar bitiřik nizam olma durumu, bitiřik nizam olmama durumu, ađır ıkma olma durumu ve ađır ıkma olmama durumundan oluřmaktadır. Elde edilen sonuların bařarımını artırılması iin eđitim parametreleri ve evriřimli sinir ađı katmanlarında iyileřtirilmeler yapılarak optimum deđerler bulunmuř ve yksek bařarım (%85 ve zeri) elde edilmiřidir. Eđitimin bařarılı olduđunu kontrol etmek iin sınıflandırılması yapılan bina cephe grntlerinde, algoritmanın grntnn hangi noktalarından znetelik ıkarttıđını kontrol etmek iin odaklanılan noktaların belirlenmesinde ısı haritaları kullanılarak algoritmanın sađlıklı ğrendiđi kontrol edilmiřtir (Selvaraju, 2017). Kullanılan n eđitimli KSA modellerinin birbiri ile performans ve bařarımları karřılařtırılmıřtır. Hangi modelin daha iyi bařarım sađladıđı tespit edilmiřtir. Yapılan karřılařtırılmanın sonucunda kullanılan modeller arasında en iyi performans veren modelin DarkNet53 olduđu ispatlanmıřtır.

Hızlı grsel tarama da kullanılan belirlenmiř parametreleri, tespit edebilen algoritmasının geliřtirildiđi bu tez alıřması toplamda beř kısımdan oluřmaktadır.

Birinci blmde tezin konusu, hızlı deđerlendirme ynetmeleri ile ilgili bilgiler verilmiř nemi, zgn deđer, amacı ve alıřma ařamalarından bahsedilirmiřtir.

İkinci blmde deprem risk analizlerinde ncelik belirlemek iin kullanılan hızlı deđerlendirme yntemleri ile ilgili literatrde yapılmıř alıřmalarından bahsedilmiřtir. Blmn devamında hızlı grsel deđerlendirme yntemleri aıklanmıř parametreleri hakkında bilgiler verilmiřtir. İkinci blmn sonunda derin renme, konvolsyonel sinir ađları hakkında bilgiler verilmiř ve tez alıřmasında kullanılan konvolsyonel sinir ađları tanıtılmıřtır.

nc blmde ise bina cephe grntlerinin nasıl elde edildiđi, elde edilen verilerin hangi iřlemlerden geirilip eđitim ve test veri setlerinin oluřturulduđu, hangi yntemler kullanılarak istenilen algoritmanın oluřturulduđundan bahsedilirmiřtir.

Dördünü bölümde eğitim sonuçları verilmiştir. Oluşturulan algoritmalar karşılaştırılarak en iyi sonuç veren algoritmanın DarkNet53 KSA modeli ile eğitilmiş algoritma olduğu ispatlanmıştır.

Son bölüm olan dördüncü bölümde ise sonuçlar tartışılmış ve gelecekte yapılabilecek çalışmalara yönelik önerilerden bahsedilmiştir.

## 2. LİTERATÜR

Dünyada ve Türkiye’de binaların depreme dayanıklılık testlerinin yapılması ve yapılan testlerin sonucunda, tespit edilen deprem açısından risk durumu kritik önem taşıyan binalardan başlanarak, binaların depreme dayanıklı hale getirilmesi depremden oluşabilecek yıkımların ve can kayıplarının önlenmesi açısından hayati bir konudur. Türkiye’de bulunan yapı stokunun büyüklüğünden dolayı Türkiye Bina Deprem Yönetmeliğinde (TBDY 2018) tarif edildiği şekilde detaylı incelemelerin yapılabilmesi zaman ve ekonomik kaynaklar açısından mümkün değildir. Bu sebeple riskli olan binaların öncelik sırasının belirlenmesi için hızlı değerlendirme yöntemleri kullanılmaktadır. Hızlı değerlendirme yöntemi kullanılarak risk öncelikleri tespit edilerek en riskli binadan başlanılarak TBDY-2018’de tarif edildiği şekilde detaylı performans testleri yapılır (Türk Bina Deprem Yönetmeliği, 2018). Performans testlerin sonucuna göre bina için gerçekleştirilecek depreme karşı yapılan iyileştirmeler sayesinde can ve mal kayıplarının önüne geçilmiş olunur.

Gerek ülkemiz gerek diğer ülke yönetmeliklerinde ve literatürde birçok hızlı değerlendirme yöntemi bulunmaktadır. Türkiye’deki hızlı değerlendirme yöntemi, 6306 sayılı Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun kapsamında Riskli Binaların Tespit Edilmesine İlişkin Esaslar (RBTEİE) ve RBTEİE EK-A kısmında belirtilen “Binaların Bölgesel Deprem Risk Dağılımını Belirlemek için Kullanılabilecek Basitleştirilmiş Yöntemler” adı altında sunulmaktadır (6306 sayılı Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun, 2012). Başka ülkelerdeki yönetmeliklerin bir kısmı ise Federal Emergency Management Agency tarafından yayınlanan FEMA 154 Hızlı Görsel Tarama (Rapid Visual Screening-RVS) yöntemi (FEMA 155-ATC-21-1, 1998), Kanada Sismik Tarama yöntemi (Manual for Screening of Buildings for Seismic Investigation, 1992), Japon Sismik İndeks yöntemi (Standard for Seismic Evaluation of Existing Reinforced Concrete Buildings, 2001), Yeni Zelanda Standardı (Assessment and Improvement of the Structural Performance of Buildings in Earthquakes, 2006) ve Hindistan Hızlı Görsel Tarama yöntemi olarak sıralanabilir (Integrated Rapid Visual Screening of Buildings for Seismic Hazard, 2014). Tezcan ve arkadaşlarının 2005 yılında yayınladıkları makalesinde, yapıların analiz edilip güçlendirilmesinin ekonomik ve zaman açısından kayıp olduğunu göstermiştir.

Binalarda hızlı tarama metotlarının kullanılıp belirlenen riskli bölgelerde detaylı sismik analizlerin yapılmasını önermiştir. Mevcut bina stokunun bilimsel olarak performans analizinin yapılabilmesi için Sıfır Can Kaybı ve P5 Yöntemini bulmuştur (Tezcan, Bal, Özdemir, & Küçük, 2005). Bal ve arkadaşları 2007 yılında yayınladıkları makalede, Tezcan ve arkadaşlarının bulduğu P5 Yöntemini geliştirerek P24 Yöntemi olarak isimlendirmiştir (Bal, Tezcan & Gülay, 2007; Tezcan, Bal, Özdemir, & Küçük, 2005). P24 Yöntemi kalibre edilip P25 Puanlama Yöntemini halini almıştır. Damcı ve arkadaşları 2003 yılında yayınladıkları makalede İstanbul ili Bakırköy ilçesindeki yapı stoğunu hızlı değerlendirirken binaları yük taşıma kapasitesine göre puanladığı DURTES adlı bir algoritma kullanmıştır (Damcı, Yıldızlar, Gürsoy, Özturun, & Çelik, 2003). Kullanılan bu metotlar ile binalara belirlenen parametreler üzerinden puanlar verilmektedir. Verilen puanlara göre de binaların sismik performans analizi için öncelik sırası belirlenmektedir.

Türkiye’de binaların sismik bakımdan hızlı değerlendirilmesi oldukça önemli bir konudur. Bu konuda saha çalışmaları ve analitik verilere dayalı akıllı yazılımlar (yapay zekâ, makina öğrenmesi, vb) kullanılmaya başlanmıştır. Akıllı yazılımlar hızlı ve yüksek doğruluk ile sonucu bulabilme özelliklerinden dolayı bize maliyetten tasarruf ve zaman kaybı açısından önemli avantajlar sağlar. Yapay zekanın bir alt kümesi olan makine öğrenmesi, bir grup örnekten öğrenen mantıksal veya ikili işlemlere dayanan otomatik hesaplama işlemlerini içeren bir çalışma alanıdır (Kotsiantis, Zaharakis, & Pintelas, 2006). Geleneksel makine öğrenme metotları sınıflandırma yapmak için öznitelik çıkarılmasına ihtiyaç duymaktadır (Kim & Kwang, 2016). Bu sebeple makina öğrenmesinde kullanılacak veriler belirli öznitelik çıkarma işlemlerinden geçirilmeleri gerekmektedir. Yapılacak olan işlemler çok miktarda zaman ve insan kaynağı gerektirmektedir. Geleneksel makina öğrenmesinde yaşanan bu problem derin öğrenme metodunda ham veri üzerinden eğitim işlemi gerçekleştirilerek aşılmıştır. Derin öğrenme, öznitelik çıkartmak için çeşitli lineer olmayan işlem birimi katmanını kullanmaktadır. Katmanlar kendinden önceki katmanın çıktısını girdi olarak alır. Literatürde ve uygulamada derin öğrenmenin kullanıldığı çok sayıda çalışma yapılmıştır. Doğal dil işleme, görüntü ve video işleme, biyomedikal sinyal ve görüntü işleme, nesne tanıma, robotik, kimya, reklam, finans, arama motorları, otonom araç

sistemleri gibi çok çeşitli konularda derin öğrenme uygulamaları geliştirilmektedir (Deng & Yu 2014).

Derin öğrenme genel olarak verinin temsilinden öğrenmeye dayanmaktadır. İlk derin öğrenme algoritmasını Ivakhnenko ve Lapa tarafından 1965 yılında yayınlanmıştır (Ivakhnenko & Lapa, 1966). Ivakhnenko'dan sonra geliştirilen ilk derin öğrenme mimarisi Fukushima'nın omurgalı canlıların görsel sinir sistemlerinden ilham alarak geliştirdiği, "denetimsiz öğrenme" ile kendi kendini organize edebilen bir ağ yapısıdır (Fukushima, 1980). Bu dönemlerde yapay sinir ağlarının KSA (Konvolüsyonel Sinir Ağları) yüksek başarımlı özellik çıkarımlarına ihtiyaç duyulmama avantajlarına rağmen eğitim sürelerinin uzun olması yeterli işlem gücünün olmamasından dolayı oluşan hesaplama maliyetlerinden dolayı kullanılmamıştır. Ancak 2000'li yıllarda bilgisayarların hesaplama gücünün artması ve GPU üzerindeki gelişmelerle birlikte yapay sinir ağlarının hesaplama maliyetlerinin düşmesinden dolayı tekrar kullanılmaya başlanmıştır (Schmidhuber, 2015).

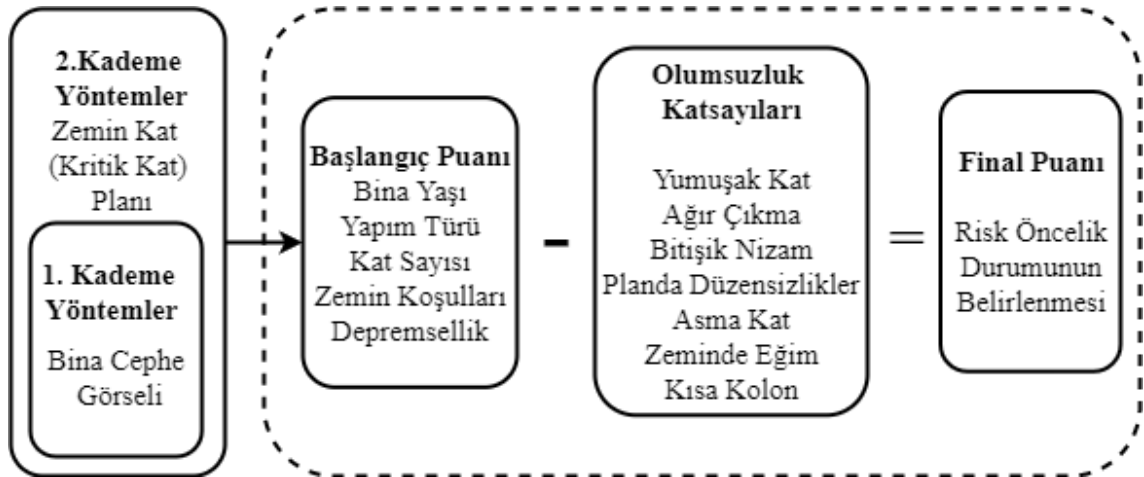
Derin öğrenme bilim dünyasında ilk büyük etkisini 2012 yılında yapmıştır. 2012 yılında alanında en büyük yarışma olan Büyük Ölçekli Görsel Tanıma Yarışması'nda (ImageNet) Krizhevsky derin öğrenmede temel mimari olarak kabul edilen KSA (konvolüsyonel sinir ağları) ile büyük bir başarı kazanmış ve konvolüsyonel sinir ağlarının başarısını kanıtlamıştır (Krizhevsky, Sutskever, & Hinton, 2012). Literatür incelendiğinde, yapay sinir ağları kullanılarak depremle ilgili bazı yapılan çalışmaları bahsetmek gerekirse; Çelik ve arkadaşları 2014 yılında yayınladıkları makalede, yapay sinir ağlarıyla sınıflandırma yaparak %83 oranında depremi erken tespitini sağlamıştır (Çelik, Enes, Atalay, & Harun Bayer, 2014). Florido ve arkadaşları 2016 yılında yayınladıkları makalede, yapay sinir ağlarını kullanarak deprem tahmini üzerine çalışmalarda bulunmuştur (Florido, Aznarte, Morales Esteban, & Martínez Álvarez, 2016). Yu ve arkadaşları 2020 yılında yaptıkları çalışmada, depremde zarar görebilecek binaların risk önceliğinin belirlemede kullanılan hızlı görsel tarama yönteminin parametrelerinden yumuşak kat parametresinin otomatik tespit algoritması geliştirilmiştir. Santa Monica ve Oakland sokaklarından bina cephe görüntüleri toplanarak eğitim ve test veri setleri oluşturulmuştur. Oluşturulan veri setleri kullanılarak derin öğrenme modelleri eğitilmiştir. Ön eğitilmiş KSA modellerinden ResNet50, ResNet152, InceptionV3, InceptionV4 modelleri kullanılmış ve sonuçlar

karşılaştırılmıştır. En iyi performans veren modelin ResNet50 olduğu ispatlanmıştır (Yu et al., 2020). Gonzalez ve arkadaşları 2020 yılında yaptıkları çalışmada, binalarda doğal afetlerden dolayı oluşabilecek yıkımları önlemek için depremde hasar görme olasılığının yüksek olan bina tiplerinin otomatik tespit edebilen bir algoritma geliştirmişlerdir. Google Haritalar Sokak Görünümü kullanarak yaklaşık 10.000 adet bina görseli elde etmişlerdir. Elde edilen görseller ile ön eğitilmiş KSA modellerinin eğitimi gerçekleştirilmiştir. Kullanılan ön eğitilmiş KSA modelleri Vgg16, Vgg19, InceptionV3, Inception, Resnet50 modelleridir. Kullanılan modeller arasında en iyi başarıyı 95% doğruluk oranı ile Resnet50 göstermiştir (Gonzalez et al., 2020). Adha ve arkadaşları 2022 gerçekleştirdikleri çalışmada, FEMA 154 de bina risk puanlamasında kullanılan parametrelerden bina tipinin derin öğrenme kullanılarak otomatik tespiti gerçekleştirilmiştir. On üç adet bina tipi için Google Haritalar Sokak Görünümü kullanılarak bina cephe görüntüleri toplanmıştır. Elde edilen veri seti ile derin öğrenme algoritması eğitilmiştir. Geliştirilen algoritma otomatik olarak binanın on üç adet bina sınıfından hangi sınıfa ait olduğunu tespit etmektedir. Yapılan çalışma Endonezya bulunan binalar için gerçekleştirilmiştir. Bina görünümleri ülkelere göre farklılık gösterdiği için diğer ülkelerde kullanılabilmesi için veri setinin geliştirilmesi gerektiğinden bahsedilmiştir (Adha, Pamuncak, Qiao, & Laory, 2022).

### 3. KURAMSAL TEMELLER

#### 3.1. Hızlı Değerlendirme Yöntemleri

Hızlı değerlendirme yöntemleri genel olarak binaların zemin koşulları, yapım cinsi, kat sayısı, yaşı, binanın yüksekliği, binanın bulunduğu yerin depremselliği, gibi parametrelere verilen başlangıç puanından, binanın yumuşak kat, ağır çıkma, bitişik nizam, planda düzensizlik, asma kat, zeminde eğim, kısa kolon gibi yapısal kusurları çıkartılarak binanın nihai puanı hesaplanmış olur. Literatürde hızlı değerlendirme yöntemleri 1. Kademe yöntemler ve ikinci kademe yöntemler olarak iki kısma ayrılmaktadır. 1. kademe yöntemler literatürde sokak taraması ismi ile de adlandırılırlar. 1. kademe yöntemler binanın dış cephe görüntüsü ve bölgesel depremsellik parametrelerini kullanarak değerlendirmeyi gerçekleştirirler. FEMA-154, Kanada Sismik Tarama Yöntemi, RTYE-2019, Sucuoğlu 1. kademe yöntemlerindedir. 2. kademe yöntemler binanın kritik katındaki (zemin kat) taşıyıcı elamanların cinslerine, boyutlarına ve yerleşimlerinden yararlanarak değerlendirme yapar. Yakut, PERA, DURTES Anadolu Üniversitesi Hızlı Değerlendirme Yöntemi 2. Kademe yöntemler arasında yer alır. Şekil 1’de hızlı değerlendirme yöntemlerinin genel akış şeması gösterilmiştir. Hızlı değerlendirme yöntemleri her bina için uygun değildir. En fazla yükseklik 8 katlı betonarme binalar için uygulanabilmektedir.



Şekil 1. Hızlı değerlendirme yöntemi akış şeması

Hızlı değerlendirme yöntemi kullanılarak yapılan risk puanlamasında kullanılan parametreleri beş grup altında toplanabilir; yapısal parametreler zemin parametreleri,



deprem parametreleri, düzensizlik parametreleri ve diğer parametreler olarak sınıflandırılabilir.

### 3.1.1. Hızlı Değerlendirme Yöntemi Parametreleri

#### 3.1.1.1. Yapısal parametreler

Yapısal parametreler hızlı değerlendirme yöntemi uygulanacak binaların bitişik nizam, yapısal sistem türü, bina görsel kalitesi, kat sayısı, bina zemin kat alanı, taşıyıcı sistem çerçeve düzensizliği gibi parametrelerden oluşmaktadır. Hızlı değerlendirme yöntemlerinin genelinde kullanılmaktadırlar ve yapılan değerlendirmelerde önemli rol oynarlar.

##### a. Bitişik nizam

Bina cephe görüntüsü üzerinden değerlendirilen parametrelerdendir. Literatürde çarpışma etkisi şeklinde de geçmektedir. Depremin gerçekleştiği esnada binalar farklı titreşim frekanslarına sahip olurlar bu durum binaların birbirine çarpmasına ve fazladan kuvvet uygulamasına neden olur. Bu durum binaların depremde daha çok hasar almasına neden olur. Şekil 2’de iki ve tek cepheden bitişik olmak üzere bitişik nizam binalar gösterilmektedir. Şekil 3’te bitişik nizam olmayan binalara ait görseller gösterilmiştir.



**Şekil 2. (a):Tek cepheden bitişik nizam bina cephe görüntüsü. (b):İki cepheden bitişik nizam bina cephe görüntüsü. (c):Tek cepheden bitişik nizam bina cephe görüntüsü.**

(Kaynak: Google Haritalar Sokak Görünümü, 2021)

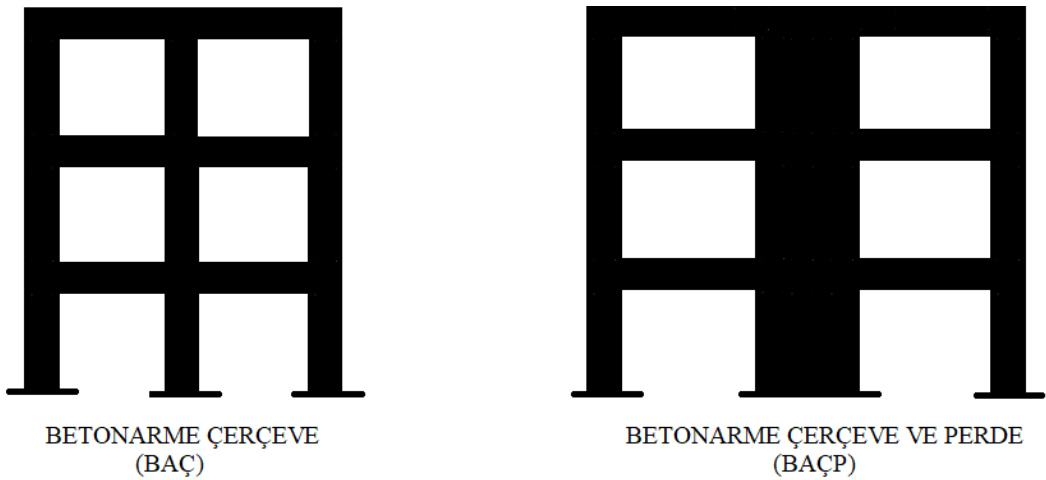


**Şekil 3. (a): Bitişik nizam olmayan bina ceph görüntüsü. (b): Bitişik nizam olmayan bina ceph görüntüsü.**

(Kaynak: Google Haritalar Sokak Görünümü, 2021)

#### b. Yapısal sistem türü

Binaların yapısal sistem türleri betonarme, çelik ve yığma gibi türlere sahiptir. En yaygın olarak bulunan tür betonarme yapılardır. Betonarme sistemler sadece kolon ve kirişlerden oluşan çerçeve sistem, sadece perdelerden oluşan perdeli sistem ve çerçeve ile perdenin beraber olduğu perde + çerçeve sistem şeklinde sınıflardan oluşmaktadır. Betonarme perdeye sahip olan binalar daha rijit bir yapıya sahiptir. Perdelerin binaya simetrik olarak uygulanması gereklidir, simetrik uygulanmadığı takdirde burulma etkilerinden önemli oranda bina zarar görebilir. Şekil 4’te yapısal sistem türleri gösterilmiştir. Bina ceph görselleri üzerinden değerlendirilen parametrelerdendir.




**Şekil 4. Yapısal sistem türü**

c. Bina görsel kalitesi

Binanın dış görünümünün kondisyon, işçilik kalitesi gibi kriterler göz önünde bulundurarak bakılan parametredir. Uzman mühendis binanın durumuna göre kötü, orta ve iyi şeklinde değerlendirmede bulunmaktadır. Değerlendirme sonucu ile deprem neticesinde binanın aldığı hasar benzerdir. Genellikle 1. kademe hızlı değerlendirme yöntemlerinde kullanılırlar.

d. Kat sayısı

Binaların kat sayısı deprem hasarlarının etkisi açısından önemli bir rol oynamaktadır. Binaların kat sayısı arttıkça depremden dolayı alacağı kuvvette artar ve bina daha çok hasar alır. Katsayısı hesaplanırken zeminin altında kalan katlar binaya negatif bir etki yapmadığından dolayı hesaba katılmaz. Şekil 5'te serbest kat adedi gösterilmiştir. Kat sayısı 1. kademe hızlı değerlendirme yöntemlerinde kullanılan parametreler arasında sonuca en çok etki eden parametrelerdendir.



Şekil 5. Serbest kat adetleri. (a):6 katlı bina. (b):6 katlı bina. (c):5 katlı bina. (d):5 katlı bina. (e):5 katlı bina.


(Kaynak: Riskli Yapıların Tespit Edilebilmesine İlişkin Esaslar, 2019)

e. Zemin (kritik) kat alanı

Ülkemizde genellikle binaların zemin katları ticari sebeplerden dolayı iş yeri olarak kullanılmaktadır. İş yerleri olarak kullanılan zemin katlarında alandan kazanmak için eksik duvarlar ve zayıf taşıyıcı elamanlar bulunmaktadır, bu sebeple kritik katlar çoğunlukla zemin katlardır. Küçülen kolon boyutları binanın rijitliğini ciddi oranda düşürdüğünden dolayı depremde hasar görme miktarını artırmaktadır. Kritik kattaki en uzun düşey ve yatay uzunluğun çarpılmasıyla bulunur. 2. kademe hızlı değerlendirme yöntemlerinde kullanılırlar.

f. Çerçeve süreksizliği

Binalarda taşıyıcı sistem elamanı olan betonarme çerçeve kirişlerinin alınmasıyla oluşan bir durumdur. Arasında bağlantı bulunmayan kirişler çevre kolonlar arasında kirişsiz bir döşeme oluşmasına sebep olur. Yatayda bağlantısı kolonların ciddi oranda rijitliği azalır. Bu düzensizlik durumu binanın simetrisini bozduğu için binada burulma momentinde sebep olur. Binanın sağlamlığı açısından istenmeyen bir durumdur.



**Şekil 6. Çerçeve süreksizliği örnek bina**

(Kaynak: Bal & Özdemir, 2006)

3.1.1.2. Düzensizlik parametreleri

Binanın statik hesabı sırasında hesaba eklenmeyen fazladan yükler neticesinde oluşan düzensizlik parametrelerdedir. Deprem esnasında bu fazladan yükler neticesinde bina yıkılabilir ciddi hasarlar alabilir. Düzensizlik parametreleri beş sınıftan oluşur bu parametreler; ağır çıkma düzensizliği, kısa kolon düzensizliği, planda düzensizlik,

yumuşak kat düzensizliği, düşeyde düzensizlik. Hızlı değerlendirme yöntemlerinde genellikle kullanılan parametrelerdendir.

a. Ağır çıkma düzensizliği

Ağır çıkma düzensizliği binanın katlarının oturduğu zemin dışarıya çıkma yapma durumudur. Bina oturduğu zeminden fazla alan elde etmek üzere gerçekleştirilen bir işlemdir. Bina kat planlarında çıkıntıya sahip olan kat ile o kata dik olan çıkıntıya sahip olmayan kat arasındaki fark %20 den fazla olduğu durumda çıkma kat olarak kabul edilir. Kapalı ve açık olmak üzere iki çeşidi mevcuttur, kapalı ağır çıkmalar daha ağır olduğu için bina daha fazla hasarlara sebep olabilirler. Ağır çıkmalar deprem esnasında ağır çıkmayı taşıyan kolonlar için önemli kesme kuvvetleri neden olurlar. Ağır çıkmaların oluşturduğu diğer bir sorun ise taşıyıcı sistem çerçeve elamanlarının sürekliliğini bozarak sistem çerçevelerinin rijitliğini azaltır. Şekil 7’ de ağır çıkma bina örneği gösterilmiştir. Ağır çıkmalar binalar için sebep olduğu olumsuzluklardan dolayı deprem sırasında binanın yıkılmasına çok ciddi hasar almasına neden olabilir. Deprem etkilerine ön görülmesi açısından önemli bir parametre olduğu için hızlı değerlendirme yöntemleri için çok önemli parametreler arasındadır.



(a)




(b)

**Şekil 7. (a):Ağır çıkma bina. (b):Depremde hasar almış ağır çıkma bina.**

(Kaynak: Google Haritalar Sokak Görünümü, 2021)

### b. Yumuşak kat düzensizliği

Yumuşak kat düzensizliği binanın zemin katında taşıyıcı sistemin zayıf olmasından dolayı oluşan bir durumdur. Yumuşak kat düzensizliği mimari nedenlerle oluşmaktadır. Zemin katlar genellikle iş yeri olarak kullanıldığı için daha fazla alan kazanmak için taşıma sistemi zayıflatılmaktadır. Yumuşak kat zemin katın yüksekliğinin diğer kat yüksekliklerinden yüksek olması, duvar yerine cam kullanılması veya taşıyıcıyı elamanları güçsüzleştirilmesinden dolayı oluşmaktadır. Bu durum zemin kat ile diğer katlar arasında ciddi rijitlik farklarına sebep olmaktadır. Oluşan rijitlik farkı deprem esnasında binanın ciddi hasarlar almasına veya yıkılmasına sebep olabilir. Hızlı değerlendirme yöntemlerinden 1. Kademe yöntemlerinde kullanılan parametrelerdendir.



**Şekil 8. Yumuşak kat örneği. (a):Yumuşak kat olmayan bina. (b):Yumuşak kat olan bina**

(Kaynak: Riskli Yapıların Tespit Edilebilmesine İlişkin Esaslar, 2019)

### c. Düşeyde düzensizlik

Düşeyde düzensizlik durumu binanın yüksekliği boyunca devam ettirilmeyen kolon veya perde den kaynaklanır. Kolonların üzerine oturtulan perdeler veya kirişlerin üzerine oturan perde şeklinde meydana gelirler. Bu durum sonucunda önemli oranda eğilme momenti ve eksenel kuvvetler meydana ve binanın hasar alıp yıkılmasına sebep olur. Yaygın görülen bir durum değildir.

#### d. Kısa kolon etkisi

Kısa kolon etkisi binanın duvarlarının kolon boyunca devam ettirilmemesinden dolayı gerçekleşen bir durumdur. Kolonlar bu sebepten dolayı uzunlukları boyunca çalışamaz ve önemli miktarda kesme kuvvetlerine maruz kalırlar. Gerçekleşen durum karşısından kolonların rijitliğinin azalmasından dolayı deprem esnasında kısa kolanlar ciddi miktarda hasar görebilirler. Hızlı değerlendirme yöntemlerinde genellikle kullanılan parametrelerdendir.

#### 3.1.2. Sokak Taraması Yöntemleri (1. Kademe Yöntemler)

Hızlı değerlendirme yöntemlerin den 1.kademe yöntemler ismi ile de geçen sokak tarama yöntemleri binaların dış cephe parametrelerini kullanarak binanın deprem analizi için öncelik puanını belirlenmesi için kullanılır. Başlıca 1. Kademe yöntemler FEMA 154, Japon Sismik İndex, Sucuoğlu Riskli Yapılar Yönetmeliği'dir. Yönetmeliklerdeki formlar bina parametreleri kullanılarak binanın nihai skoru hesaplanır (Sucuoğlu, 2007).

##### 3.1.2.1. FEMA 154

FEMA 154 Amerika Birleşik Devleti Federal Acil Durum Yönetim Kurulu tarafından hızlı görsel tarama ismi ile yapılan hızlı değerlendirme yöntemidir. En çok kullanılan hızlı değerlendirme yöntemlerindendir son halini 2015 yılında almıştır. Yöntemde belirtilen başlangıç puan parametreleri ile binanın başlangıç puanı oluşturulur, binanın olumsuz parametrelerden aldığı puandan çıkartılarak binanın nihai skoru bulunur. Yöntemin belirlediği eşik değerden yüksek ise güvenli bina düşük ise riskli bina olarak sınıflandırılır. Riskli binalar kendi aralarında çok yüksek, yüksek, orta derece yüksek, orta ve düşük olmak üzere 5 sınıfa ayrılırlar. Yöntem 3 aşamadan oluşmaktadır. Örnek Form ek 1'de mevcuttur.

İlk aşama taşıyıcı sistem türü Tablo 1'den seçilir ve deprem risk seviyesine göre başlangıç puanı belirlenir

**Tablo 1. FEMA 154 bina türleri**

Simge	Bina Tanımı
W1	Taban alanı 3000m <sup>2</sup> ve daha az olan ticari ya da konut türü ahşap olan yapılar
W2	Taban alanı 5000m <sup>2</sup> den büyük ahşap yapılar
S1	Moment aktaran çelik çerçevesel yapılar
S2	Berkitilmiş çelik çerçevesel yapılar
S3	Hafif metal yapılar
S4	Yerinde dökme betonarme perde duvarlı çelik çerçevesel yapılar
S5	Yığma duvarlı çelik çerçevesel yapılar
C1	Moment aktaran betonarme çerçevesel yapılar
C2	Beton perde duvarlı yapılar
C3	Yığma duvarlı betonarme çerçevesel yapılar
PC1	Prefabrik betonarme panel duvarlı yapılar
PC2	Prefabrik betonarme çerçevesel yapılar
RM1	Beton dolgu ile güçlendirilmiş yığma binalar
URM	Yığma yapılar

(Kaynak: FEMA 154, 2015)

İkinci aşama binanın sahip olduğu olumsuzluk parametrelerine tekabül eden puanlar Tablo 2 üzerinden seçilir.

**Tablo 2. FEMA 154 Olumsuzluk parametreleri**

FEMA BINA TİPİ	W1	S1	S2	S3	S4	C1	C2	C3	PC1	PC2	RM1	URM
Başlangıç Puanı	3.6	2.1	2.0	2.6	2.0	1.5	2.0	1.2	1.6	1.4	1.7	1.0
Düşey Düzensizlik (Yüksek)	-1.2	-1.0	-1.0	-1.1	1.0	-0.9	-1.0	-0.7	-1.0	-0.9	-0.9	-0.7
Düşey Düzensizlik (Orta)	-0.7	-0.6	-0.6	-0.7	-0.6	-0.5	-0.6	-0.4	-0.6	-0.5	-0.5	-0.4
Plan Düzensizliği	-1.1	-0.8	-0.7	-0.9	-0.7	-0.6	-0.8	-0.5	-0.7	-0.6	-0.7	-0.4
Yapım yılı	-1.1	-0.6	-0.6	-0.8	-0.6	-0.4	-0.7	-0.1	-0.5	-0.3	-0.5	0
Yönetmeliğe Uygunluk	1.6	1.4	1.4	1.1	1.9	1.9	2.1	0	2.0	2.4	2.1	0
Zemin Tipi (A veya B)	0.1	0.4	0.6	0.1	0.6	0.4	0.5	0.3	0.6	0.4	0.5	0.3
Zemin Tipi E(1-3 Kat)	0.2	-0.2	-0.4	0.2	-0.1	0	0	-0.2	-0.3	-0.1	-0.1	-0.2
Zemin Tipi E (>3 Kat)	-0.3	-0.6	-0.6	0	-0.6	-0.5	-0.7	-0.3	0	-0.4	-0.5	-0.2
Sınır Puanı	1.1	0.5	0.5	0.6	0.5	0.3	0.3	0.3	0.2	0.2	0.3	0.2

(Kaynak: FEMA 154, (2015))



Son aşama belirlenen puanlar toplanarak nihai deprem performans skoru elde edilir. Çıkan sonuç Tablo 3'ten seçilen sınır değeri ile karşılaştırılır, sınır değerinden büyükse güvenli bina küçükse riskli bina olarak adlandırılır.

### 3.1.2.2. Riskli Yapılar Yönetmeliği

Deprem riskli binalar arasında öncelik belirlemede kullanılan yöntemi, diğer hızlı değerlendirme yöntemleri gibi binanın belirlenen başlangıç puanından olumsuz parametrelerin çıkartılmasıyla hesaplanmaktadır. Değerlendirme 5 aşamadan oluşmaktadır.

İlk aşama binanın başlangıç puanını belirleyen parametrelerden zemin sınıfı ve spektral ivme katsayısı karşılık gelen tehlike bölgesi Tablo 3'ten belirlenir.

**Tablo 3. FEMA 154 Deprem tehlike bölgeleri**

<b>Tehlike bölgesi</b>	<b><math>S_{DS}</math></b>	<b>Zemin Sınıfı</b>
I	$S_{DS} \geq 1.0$	ZC/ZD/ZE
II	$S_{DS} \geq 1.0$	ZA/ZB
	$1.0 \geq S_{DS} \geq 0.75$	ZC/ZD/ZE
III	$1.0 \geq S_{DS} \geq 0.75$	ZA/ZB
	$0.75 \geq S_{DS} \geq 0.50$	ZC/ZD/ZE
IV	$0.75 \geq S_{DS} \geq 0.50$	ZA/ZB
	$0.50 \geq S_{DS}$	Tüm zeminler

(Kaynak: Riskli Yapıların Tespit Edilebilmesine İlişkin Esaslar, 2019)

İkinci aşama binanın taşıyıcı tipine göre yapısal sistem puanı ve tehlike bölgesine göre bina taban puanının katsayısını Tablo 4'ten belirlenir.

**Tablo 4. FEMA 154 Taban ve yapısal sistem puan tablosu**

Toplam Kat Sayısı	Taban Puanı (TP)				Yapısal Sistem Puanı (YSP)	
	Tehlike Bölgesi				Yapısal Sistem	
	I	II	III	IV	BAÇ	BAÇP
1 ve 2	90	120	160	195	0	100
3	80	100	140	170	0	85
4	70	90	130	160	0	75
5	60	80	110	135	0	65
6 ve 7	50	65	90	110	0	55

(Kaynak: Riskli Yapıların Tespit Edilebilmesine İlişkin Esaslar, 2019)

Üçüncü aşamada binanın olumsuzluk parametrelerine karşılık gelen değerler Tablo 5'ten belirlenir.

**Tablo 5. Olumsuzluk parametre puanları**

Toplam Kat Sayısı	Yumuşak Kat	Görünen Kalite	Ağır Çıkma	Kat Seviyesi/Bağımsız Bina				Düşeyde Düzensizlik	Planda Düzensizlik	Kısa Kolon	Tabii Zemin Etkisi
				Durumu							
				Aynı		Farklı					
1,2	-10	-10	-10	0	-10	-5	-15	-5	-5	-5	-3
3	-20	-10	-20	0	-10	-5	-15	-10	-10	-5	-3
4	-30	-15	-30	0	-10	-5	-15	-15	-10	-5	-3
5	-30	-25	-30	0	-10	-5	-15	-15	-10	-5	-3
6,7	-30	-30	-30	0	-10	-5	-15	-15	-10	-5	-3

(Kaynak: Riskli Yapıların Tespit Edilebilmesine İlişkin Esaslar, 2019)

Dördüncü aşamada binanın aldığı tüm puanlar toplanır ve nihai skor elde edilir. Son aşamada ise binaların aldığı puanlara risk performansları sıralanır. Puanı en fazla olan bina en az riski sahip olan, en az puana sahip olan bina en fazla riske sahip olan binadır.

### 3.2. Derin Öğrenme

Makine öğrenmesinin bir alt dalı olan derin öğrenme, sınıflandırma ve özellik çıkartımı için geliştirilmiştir bir yöntemdir. Son zamanlarda donanımlardaki ve veri setlerindeki gelişmelerden dolayı derin öğrenmenin kullanımı artmıştır. Doğal dil işleme, görüntü işleme ve sınıflandırma gibi alanlarda yüksek başarımlar göstermektedir. Derin öğrenme doğrusal olmayan çoklu katmanlardan oluşmaktadır. Katmanlar bir önceki katmanın

çıktısını alarak doğrusal olmayan dönüşüm işlemi gerçekleştirerek, çıktıyı bir sonraki katmana aktarır. Makine öğrenmesinde eğitimi gerçekleştirmek için ham veriler üzerinden öz nitelikler çıkartılır ve eğitim işlemi bu öz nitelikler kullanılarak yapılır. Derin öğrenmede ham veri öz nitelik çıkartılmadan ham şekilde kullanılır. Öznitelikleri derin öğrenme kendisi ham veri üzerinden çıkartır. Geleneksel yöntemlere göre otomatik öznitelik çıkartılması hem zaman açısından hem de veriyi en iyi temsil eden öz niteliklerin tespitinde yüksek başarımlar sağlamaktadır. (Bengio, Courville, & Vincent, 2013). Bu tez çalışmasında bir derin öğrenme modeli olan konvolüsyonel sinir ağları kullanılmıştır.

### 3.2.1. Konvolüsyonel Sinir Ağları

Katmanlarında doğrusal olmayan fonksiyonlara ve birçok konvolüsyon katmanına sahip sistemlerdir. KSA yapılarının çıkış üretmesi için giriş katmanına konvolüsyon uygulanır ve bir katmandaki tüm nöronlar sonraki katmandaki tüm katmanlara bağlıdır. Bu bağlantıya sahip olan katmanlar tam bağlı katman olarak adlandırılır. Bütün katmanlara farklı filtreler uygulandıktan sonra birleştirilir. Eğitim sırasında KSA filtrelerin özniteliklerini, gerçekleştirilmesi istenen işleme göre otomatik olarak öğrenir. Bu sebeple başlangıçtan sona doğru her katmanda görüntünün özniteliklerini basitten karmaşığa doğru öğrenilmiş olur. Şekil 9’de örnek KSA yapısı gösterilmektedir.



**Şekil 9. Konvolüsyonel sinir ağı yapısı**

(Kaynak: MathWorks, 2020)


### 3.2.1.1. KSA katmanları

#### a. Giriş katmanı

İşlenmemiş verinin KSA yapıda girdiği ilk katmandır. Giriş katmanına gelen verinin boyutu eğitimin süresini ve başarısını doğrudan etkilemektedir. Giren verinin boyutu artarsa eğitim süresi uzar fakat ağın derinliği ve başarımı artar. Verinin azaldığı durumda tam tersi bir sonuç gerçekleşir.

#### b. Konvolüsyon katmanı


Veriden özellik çıkartımı ve özellik algılanması bu katmanda gerçekleşir. Tüm konvolüsyon işlemlerinin bir çekirdeği vardır. Görüntüye uygulanacak filtreler ve çekirdekler görüntü matrisinden küçük matrislerdir. Filtre giren veri üzerin belirlenen adım miktarı kadar kaydırılır matrisin sonuna geldiği zaman bir alt satıra geçerek işleme devam eder. Yapılan işlem sonucunda özellik haritası matrisi oluşturulur.



Şekil 10. Örnek konvolüsyon işlemi

#### c. Havuzlama katmanı

Havuzlama katmanı, konvolüsyon işleminden sonraki katmandır. Katmana giren verinin boyutu azaltılarak daha sade hale getirilir. Sadeleştirme işlemini gerçekleştirmek için havuzlama katmanı verinin belirlenen filtreye göre ortalama veya maksimumu alınır. Şekil 11'de maksimum havuzlama örneği gösterilmiştir. Sadeleştirme sonucunda verinin derinliği azalmaz sadece yüksekliği ve genişliği azalır. Verinin boyutu küçüldüğü için bir sonraki katmanın hesaplama yükü azaltılmış olur. Bu sayede oluşabilecek aşırı öğrenme riskinin azaltılması sağlanır. Genel olarak tüm konvolüsyon katmanlarından sonra havuzlama katmanı gelir.



**Şekil 11. Maksimum havuzlama örneği**

d. Tam Bağlantılı Katman

Tam bağlı katmandaki tüm nöronlar, önceki katmandaki tüm aktivasyon katmanlara bağlıdır. Konvolüsyon ve havuzlama işlemleri sonucunda üretilen veriler bu katman tarafından işleme alınmakta ve işlem sonucunda sınıf sayısı kadar çıktı elde edilmektedir.

e. Çıkış katmanı

Ağ yapısının son katmanıdır sınıflandırma işleminin gerçekleştirilir. Çalışmanın ihtiyacına göre farklı sınıflandırıcılar kullanılabilir ama genellikle iyi performans gösterdiği için softmax kullanılır.

f. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları hücreye gelen veriyi işler ve bir sonuç oluşturur. Çok katmanlı sinir ağlarında doğrusal olmayan dönüştürme işlemlerinde görev alırlar. Yapılan işlem sonucunda yapay sinir ağları doğrusal olmayan bir nitelik kazanır. Yaygın olarak kullanılan Düzleştirilmiş doğrusal birim işlem (ReLU) örneği Şekil 12’de gösterilmiştir.

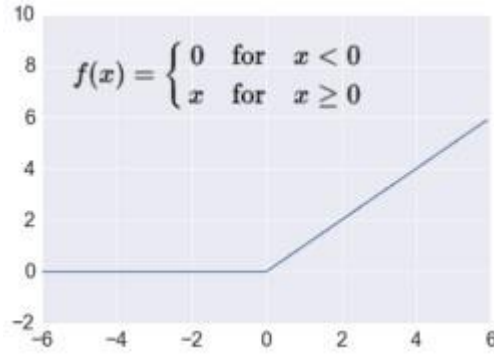
12	67	-4	85
5	1	3	6
1	-1	-37	-21
-15	0	1	82

→

12	67	0	85
5	1	3	6
1	0	0	0
0	0	1	82

**Şekil 12. Düzleştirilmiş doğrusal birim işlem örneği. (a): Düzleştirilmiş doğrusal birime giren (4x4) matris. (b): Düzleştirilmiş doğrusal birimde işlem görün matrisin çıktısı.**


Düzleştirilmiş doğrusal birim (ReLU) öğrenmeyi hızlandırmak amaçlı veriyi doğrusal olmayan bir hale getirir. Gizli katmanlarda en çok tercih edilen aktivasyon fonksiyondur. Giriş değeri 0'dan büyük ise bir, küçük ise sıfır çıkışını veren fonksiyondur.



**Şekil 13. Düzleştirilmiş doğrusal birim (ReLU) aktivasyon fonksiyonu grafiği**

(Kaynak: Kdnuggets, 2017)

Sigmoid fonksiyonu, Doğrusal olmayan çıktı vermesinden dolayı ağ yapılarında çokça tercih edilen bir fonksiyondur. Çıktısı sıfır ile bir arasında bir değerdir.



**Şekil 14. Sigmoid aktivasyon fonksiyonu grafiği**

(Kaynak: Kdnuggets, 2017)

Softmax fonksiyonu aktivasyon katmanlarında en çok tercih edilen fonksiyondur. Çıkış değerinde normalleştirilmiş olasılık dağılımı gerçekleştirir.

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

(1)

Denklemler ile softmax fonksiyonu ifade edilir.

### 3.2.2. Konvolüsyonel Sinir Ağı Modelleri

#### 3.2.2.1. VGGNet

VGGNet mimarisi 2014 yılında düzenlenen ILSVRC yarışmasında (ImageNet Large Scale Visual Recognition Challenge) görüntü sınıflandırma yarışmasında çok iyi başarı göstermiş ve ikinci olmuştur. VGGNet benzer mimarilerden farklı olarak derin bir ağ yapısına sahiptir fakat işlem yükünü azaltmak için daha küçük olan 3x3 konvolüsyon filtreleri tercih edilmiştir. Mimarinin sahip olduğu derin ağ yapısı sayesinde kompleks görüntüler üzerinde bile öznetelik çıkartımın da başarı göstermiştir. Ağ mimarisinin girdisi 224x224 piksel boyutunda RGB bir resimdir. Tablo 6'da VGGNet mimarisinin tüm parametre ve katmanları gösterilmiştir.

**Tablo 6. VGGNet mimarisi parametreleri ve katmanları**

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight Layers	16 weight layers	19 weight layers
Input (224x224 RGB image)					
Conv3-64	Conv3-64 <b>LRN</b>	Conv3-64 <b>Conv3-64</b>	Conv3-64 Conv3-64	Conv3-64 Conv3-64	Conv3-64 Conv3-64
Maxpool					
Conv3-128	Conv3-128	Conv3-128 <b>Conv3-128</b>	Conv3-128 Conv3-128	Conv3-128 Conv3-128	Conv3-128 Conv3-128
Maxpool					
Conv3-256	Conv3-256 Conv3-256	Conv3-256 Conv3-256	Conv3-256 <b>Conv3-256 Conv1-256</b>	Conv3-256 Conv3-256 <b>Conv3-256</b>	Conv3-256 Conv3-256 Conv3-256 <b>Conv3-256</b>
Maxpool					
Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512 <b>Conv1-512</b>	Conv3-512 Conv3-512 <b>Conv3-512</b>	Conv3-512 Conv3-512 Conv3-512 <b>Conv3-512</b>
Maxpool					
Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512 <b>Conv1-512</b>	Conv3-512 Conv3-512 <b>Conv3-512</b>	Conv3-512 Conv3-512 Conv3-512 <b>Conv3-512</b>
Maxpool					
FC-4096					
FC-4096					
FC-1000					
Soft-max					

(Kaynak: Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016)

VGGnet mimarisi kullanılırken tercih edilen konvolüsyon katman ve tam bağlı katman sayısına göre farklı isimler alır. En çok tercih edilen VGGNet mimarileri VGG16 ve VGG19 mimarileridir. VGG16 mimarisi 13 adet konvolüsyon katmanı ve 3 adet tam bağlı katmandan oluşmaktadır. VGG16 mimarisi toplamda 41 adet katmandan oluşmaktadır. VGG19 mimarisi 16 adet konvolüsyon katmanı ve 3 adet tam bağlı katmandan oluşmaktadır. Aktivasyon katmanı için düzleştirilmiş doğrusal birim fonksiyonu kullanılmıştır.

### 3.2.2.2. DarkNet

DarkNet mimarisi yaygın olarak kullanılan tek aşamalı gerçek zamanlı nesne algılama modeli olan you only look once (YOLO) modelinde özellik çıkarma ağı olarak kullanılmaktadır. YOLO algoritmasında öznitelik tanımlayıcısı olarak kullanılabilmesi



için DarkNet mimarisinden tam bağlantılı ve softmax katmanları çıkartılmaktadır. Yaygın olarak DarkNet19 ve DarkNet53 modelleri kullanılmaktadır. Tablo 7’de DarkNet 53 mimarisinin parametre ve katmanları gösterilmiştir. Ağ mimarisinin girdisi 224x224 piksel boyutunda RGB bir resimdir. Karar katmanı olarak softmax fonksiyonu kullanılmaktadır.

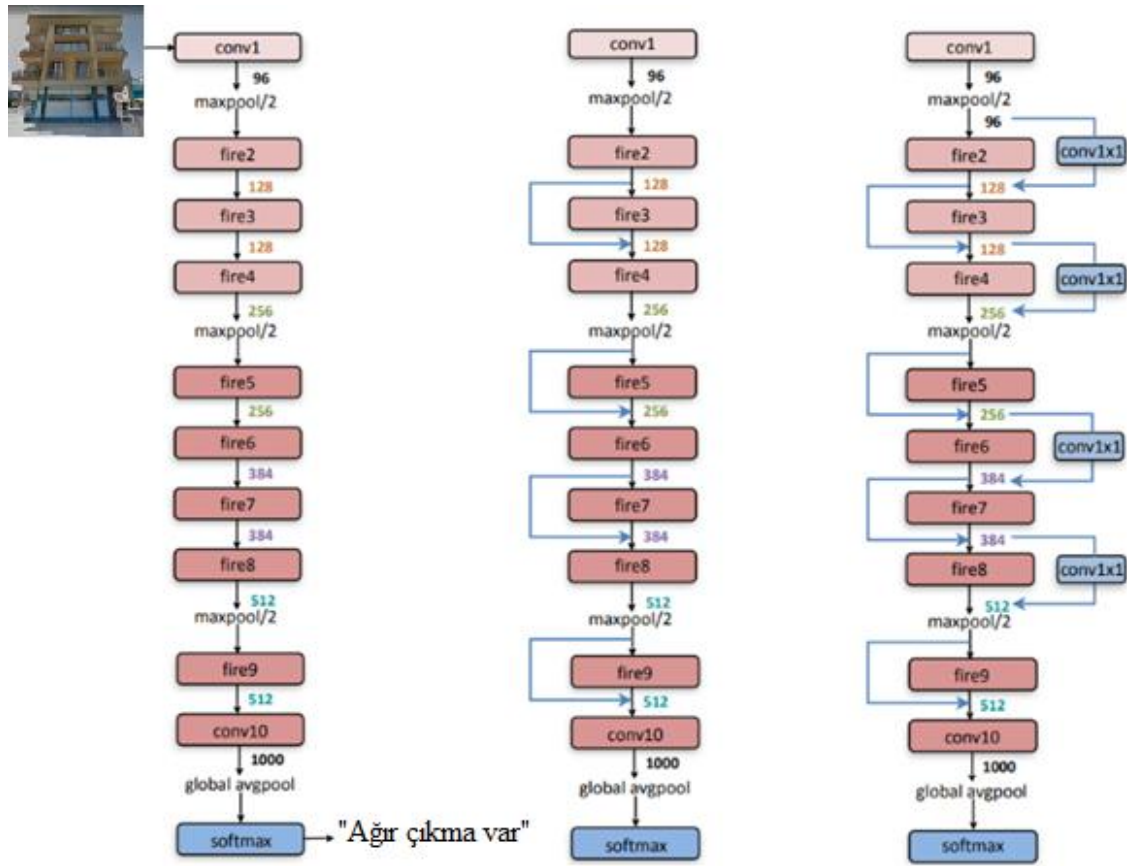
**Tablo 7. DarkNet53 mimarisi parametreleri ve katmanları**

	Type	Filters	Size	Output
	Convolutional	32	3x3	256x256
	Convolutional	64	3x3 / 2	128x128
1x	Convolutional	32	1x1	
	Convolutional	64	3x3	
	Residual			128x128
	Convolutional	128	3x3 / 2	64x64
2x	Convolutional	64	1x1	
	Convolutional	128	3x3	
	Residual			64x64
	Convolutional	256	3x3 / 2	32x32
8x	Convolutional	128	1x1	
	Convolutional	256	3x3	
	Residual			32x32
	Convolutional	512	3x3 / 2	16x16
8x	Convolutional	256	1x1	
	Convolutional	512	3x3	
	Residual			16x16
	Convolutional	1024	3x3/2	8x8
4x	Convolutional	512	1x1	
	Convolutional	1024	3x3	
	Residual			8x8
	Avgpool		Global	
	Connected		1000	
	Softmax			

(Kaynak: Geng, Ma, & Huang, 2020)

### 3.2.2.3. SqueezeNet

SqueezeNet yaygın olarak kullanılan ön eğitimli konvolüsyonel sinir ağ mimarilerinden biridir. (Iandola et al., 2016) tarafından geliştirilmiştir. Mimarinin geliştirme amacı diğer yüksek başarımlı gösteren mimariler yüksek başarımlı gösterebilen ve aynı zamanda daha az işlem yükü gerektiren bir mimarı geliştirmektir. Bu özellikleri sayesinde çok daha hızlı çalışmaktadır. Bellek ihtiyacı azaltılmıştır. Mimarinin daha sade hale gelmesi için 3x3 filtreler yerine 1x1 filtreler kullanılmıştır. Şekil 15'te katman yapısı gösterilmiştir.



Şekil 15. SqueezeNet katman yapısı

(Kaynak: Iandola et al., 2016)

## 4. VERİ SETİ VE METODOLOJİ

### 4.1. Veri Seti

Tez çalışmasında gerçekleştirilen, hızlı değerlendirme metodu parametrelerinden ağır çıkma ve bitişik nizam parametrelerinin tespitini gerçekleştiren KSA modelinin eğitilmesinde kullanılan veri seti görselleri, Google Haritalar Sokak Görünümleri üzerinden bina cephe görüntüleri toplanmıştır. 512×512 piksel boyutunda bina cephe görselleri toplanırken binalar bitişik nizam ve ağır çıkma durumuna sahip olma ve olmama olarak gruplandırılmıştır. Toplanan görseller eğitimde kullanılmak üzere sahip olduğu özelliklere göre sınıflara ayrılmıştır. Veri setinde bulunan bitişik nizam bina cephe görsel örnekleri Şekil 16' te gösterilmiştir. Şekil 16(a)'da tek cepheden bitişik nizam bina görseli gösterilmiştir. Şekil 16(b) ve 16(c)'de iki cepheden bitişik nizam bina görseli gösterilmiştir.



**Şekil 16. Bitişik nizam durumu olan binalar. (a): 3 katlı tek cepheden bitişik nizam bina. (b): 4 katlı tek cepheden bitişik nizam bina. (c) 2 katlı iki cepheden bitişik nizam bina.**

(Kaynak: Google Haritalar Sokak Görünümü)

Oluşturulan sınıflar arasındaki görüntü sayısındaki dengesizliklerin giderilmesi için eksik olan sınıfın görüntüleri aynalama ve gürültü ekleme metodu kullanılarak çoğaltılmış miktarı eksik olan sınıflar arasındaki dengesizlikler giderilmiştir. Şekil 17'de aynalama ve gürültü eklenmiş bitişik nizam bina resimleri gösterilmiştir. Şekil 17(a)'da görüntünün orijinal hali gösterilmiştir. Şekil 17(b)' de aynalama işlemi uygulanmış bitişik nizam bina gösterilmiştir. Aynalanan görüntüye gürültü eklenmiştir. Şekil 17(c)'de gösterilmiştir.



**Şekil 17. Bitişik nizam durumu aynalama ve gürültü eklenerek veri artırılması.**  
**(a):Ham bitişik bina görseli. (b): Aynalanmış bitişik nizam bina görseli.**  
**(c):Gürültü eklenmiş aynalanmış bitişik bina görseli.**

(Kaynak: Google Haritalar Sokak Görünümü)

Google Haritalar Sokak Görünümleri üzerinden toplamda 4500 adet bina cephe görseli alınmıştır. Sokak görüntüleri için sınıflandırma yapılacak olan özellikleri taşıyan ve taşımayan binalar olmak üzere görseller toplanmıştır. Toplanan görsellerin taşıdığı özelliklerine göre etiketlemeleri gerçekleştirilmiştir. Şekil 18’de Ağır çıkma binalar gösterilmiştir. Şekil 18(a)’da 4 katlı ağır çıkma bina gösterilmiştir. 18(b)’de 2 katlı ağır çıkma bina gösterilmiştir. 18(c)’de 3 katlı ağır çıkma bina örneği gösterilmiştir.



**Şekil 18. Ağır çıkma binalar. (a): 5 katlı ağır çıkma bina. (b): 3 katlı ağır çıkma bina. (c): 4 katlı ağır çıkma bina.**

(Kaynak: Google Haritalar Sokak Görünümü)

Etiketlenen görseller oluşturulan dosya gruplandırma algoritmaları kullanılarak bitişik nizam ve ağır çıkma durumları için ikili sınıflar oluşturulmuştur. Ağır çıkma durumu için 3107 adet bina cephe görseli ve ağır çıkma olmama durumu için 1393 adet bina görseli elde edilmiştir. Bitişik nizam durumu için 1077 adet bina cephe görseli ve bitişik

nizam olmama durumu için 3423 adet bina görseli elde edilmiştir. Veri setinde oluşan bu dengesizlik eğitimin sağlıklı gerçekleşmemesine sebep olabileceği düşüncesiyle eksik olan sınıflara aynalama ve gürültü ekleme metotları uygulanarak görsel sayısı dengelenmiştir. Ağır çıkma veri setini dengelemek ağır çıkma olmayan bina görüntü miktarı 2 katına çıkartılmıştır. Görüntüler orijinal resme x ekseninde 180° aynalama işlemi uygulanarak yeni bir görüntü elde edilmiştir. Bitişik nizam veri setinin dengelenmesi için bitişik nizam olmayan bina görüntüleri 3 katına çıkartılmıştır. Verileri 3 katına çıkartmak orijinal görüntü x ekseninde 180° aynalama ve aynalanan görüntüye  $\mu=0$  ortalama ve  $\sigma=0.01$  standart sapma değeri olan gaussian gürültü ekleme işlemi uygulanarak, 2 yeni görüntü elde edilmiştir. Tablo 8’de bitişik nizam binalar için dengelenmiş ve dengelenmemiş veri seti miktarı gösterilmektedir.

**Tablo 8. Bitişik nizam veri seti dengeli ve dengesiz veri adetleri**

Bitişik Nizam Durumu	Ham Görüntü Adeti	Artırılmış Görüntü Adeti
Var	1077	3231
Yok	3423	3423

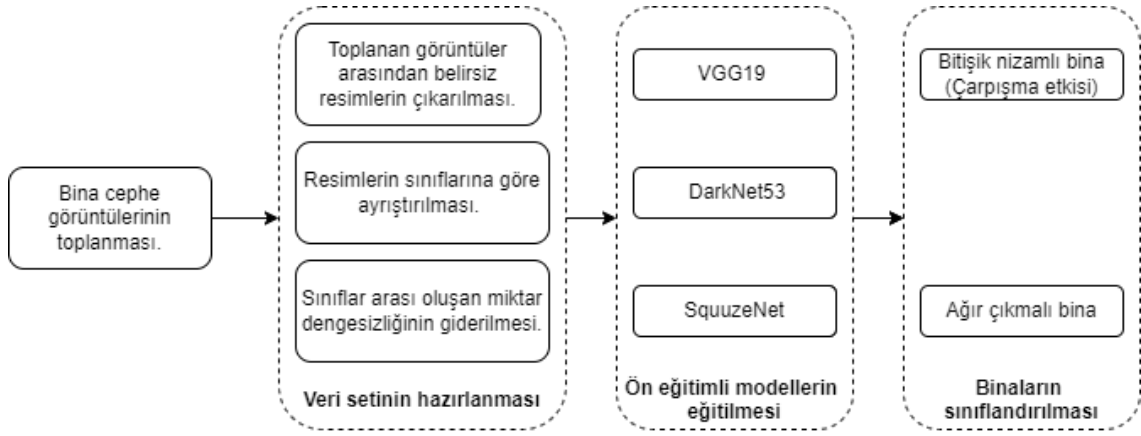
Tablo 9’da ağır çıkma binalar için dengelenmiş ve dengelenmemiş veri seti miktarı gösterilmektedir. Veri setinin %20’si sınıflandırmanın test edilmesi ve kalan %80 modelin eğitilmesi için kullanılmak üzere bölünmüştür. Bitişik nizam bina sınıflandırılması için yapılan eğitimlerde 1116 adet görüntü test veri seti ve 4461 adet görüntü eğitim veri seti için kullanılmıştır. Bitişik nizam sınıflandırma için yapılan eğitimlerde toplamda 5577 adet görüntü kullanılmıştır. Ağır çıkma binaların sınıflandırılması için yapılan eğitimlerde 1178 adet görüntü test veri seti için kullanılmıştır. Eğitim veri setinde 4715 adet görüntü kullanılmıştır. Ağır çıkma binaların sınıflandırma için yapılan eğitimlerde toplamda 5577 adet görüntü kullanılmıştır.

**Tablo 9. Ağır çıkma veri seti dengeli ve dengesiz veri adetleri**

Ağır Çıkma Durumu	Ham Görüntü Adeti	Artırılmış Görüntü Adeti
Var	3107	3170
Yok	1393	2786

## 4.2. Metotlar

Bina sınıflandırma algoritmasının hazırlanması için derin öğrenme metodundan yararlanılmıştır. Hazırlanan veri setleri kullanılarak ön eğitilmiş VGG19, Darknet19, SqueezeNet modelleri eğitilmiştir. Sınıflandırma yapan algoritmanın doğruluğunun test edilmesi için algoritmanın, görüntünün hangi bölgelerine bakarak karar verdiğini ısı haritaları kullanılarak tespit edilmiştir. Şekil 19’da bitişik nizam ve ağır çıkma bina sınıflandırma akış diyagramı verilmiştir.



**Şekil 19. Bitişik nizam ve ağır çıkma bina sınıflandırma akış diyagramı**

Derin öğrenmenin gerçekleştirildiği sistem özellikleri Tablo 10’da verilmiştir. Eğitimlerin gerçekleşebilmesi için kullanılan bilgisayarın hafıza ve işlem gücüne göre optimum eğitim parametreleri seçilmiştir. Optimum eğitim parametreleri denenerek bulunmuştur. Eğitimin hızlı ve sağlıklı bir şekilde gerçekleşmesi sağlanmıştır.

**Tablo 10. Donanım özellikleri**

İsim	Özellik
Ekran Kartı	Nvidia RTX2070 8 GB
İşlemci	Intel Core i7-9700K CPU @3.60 GHz
Ram Hafızası	16 GB
İşletim Sistemi	Windows 10 64 bit

Eğitim için kullanılan modeller kendilerine özgü katman mimarilerine sahiptirler. Ön eğitilmiş modellerin sahip olduğu farklılıklardan dolayı farklı performanslar göstermişlerdir. Eğitilmiş modellere test için ayrılan veri setleri kullanılarak modellerin

başarımları test edilmiştir. Modellerin başarımları değerlendirilirken doğruluk oranlarının yanında karar vermek için resmin hangi bölgesine odaklanarak karar verdiği kontrol edilmiştir.

#### 4.2.1. Bitişik Nizam Binaların Sınıflandırılması

Yapılan tez çalışmasında bitişik nizam durumunu tespit etmek için VGG19, DarkNet53, SqueezeNet mimarileri kullanılarak 3 ayrı eğitim gerçekleştirilmiştir. Eğitilen modeller ikili sınıflandırma yapmaktadır. Veri setinde ki 4500 adet görüntü 224 x 224 x 3 boyutunda sisteme yüklenmiştir. Veri setinin %80'ni eğitim, %20'si test için kullanılmıştır

##### 4.2.1.1. VGG19 Mimarisi Kullanılarak Bitişik Nizam Binaların Sınıflandırılması

Sisteme yüklenen eğitim verisi konvolüsyonel sinir ağının ilk katmanı olan giriş katmanına 224 x 224 x 3 boyutunda alınmıştır. Katmana giren görüntüye Tablo 10'da gösterilen parametrelerde konvolüsyon filtresi uygulanır. Filtre uygulanmış görüntüye sırasıyla Düzleştirilmiş Doğrusal Birim (DDB) ve Maksimum Örnekleme uygulanır. Sınıflandırmanın gerçekleştirilmesi Tamamen bağlı katman, DDB, Softmax katmanları kullanılmıştır. Kullanılan Parametreler ve katman miktarları Tablo 11'de gösterilmiştir.

**Tablo 11. VGG19 katmanları ve parametreleri**

Adet	Katmanlar	Aktivasyonlar	Dolgu	Kaydırma
1	Giriş Görüntüsü	224 x 224 x 3		
2	Konvolüsyon filtresi	224 x 224 x 64	1	1x1
	DDB	224 x 224 x 64		
1	Maksimum Örnekleme	112 x 112 x 64		2x2
2	Konvolüsyon filtresi	112 x 112 x 128	1	1x1
	DDB	112 x 112 x 128		
1	Maksimum Örnekleme	56 x 56 x 128		2x2
4	Konvolüsyon filtresi	56 x 56 x 256	1	1x1
	DDB	56 x 56 x 256		
1	Maksimum Örnekleme	28 x 28 x 256		2x2
4	Konvolüsyon filtresi	28 x 28 x 512	1	1x1
	DDB	28 x 28 x 512		
1	Maksimum Örnekleme	14 x 14 x 512		2x2
4	Konvolüsyon filtresi	14 x 14 x 512	1	1x1
	DDB	14 x 14 x 512		
1	Maksimum Örnekleme	7 x 7 x 512		2x2
1	Tamamen Bağlı	1 x 1 x 4096		
	DDB	1 x 1 x 4096		
	Veri düşürme	1 x 1 x 4096		
1	Tamamen Bağlı	1 x 1 x 4096		
	DDB	1 x 1 x 4096		
1	Veri düşürme	1 x 1 x 4096		
1	Tamamen Bağlı	1 x 1 x 2		
1	Softmax	1 x 1 x 2		
1	Sınıflandırma Çıkışı	1 x 1 x 2		

Eğitimin gerçekleşmesi gereken eğitim parametreleri kullanılan veri seti ve eğitimin yapıldığı bilgisayarın donanım özelliklerine göre belirlenmiştir. Eğitim parametreleri belirlenirken eğitimin hızlı ve sağlıklı bir şekilde gerçekleşmesi hedeflenmiştir. Eğitimin parametreleri denenerek optimum değerler bulunmuştur. Kullanılan parametrelere göre ram 'de kullanılan hafıza iterasyon sayıları değişmektedir. Oluşturulan ağ mimarisi ile eğitim seti kullanılarak eğitimler Tablo 12'deki eğitim parametreleri kullanılarak gerçekleştirilmiştir.



**Tablo 12. Bitişik nizam VGG19 eğitim parametreleri**

<b>Eğitim Parametreleri</b>	<b>Değer</b>
Model Adı	VGG19
Yığın Sayısı (Batch Size)	8
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	55700
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4461
Test Seti Sayısı	1116

Bitişik nizam bina sınıflandırma için oluşturulan veri seti kullanılarak, hazırlanan VGG19 modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.1.2. DarkNet53 Mimarisi Kullanılarak Bitişik Nizam Binaların Sınıflandırılması

DarkNet53 mimarisine eğitim setindeki veriler 224x224 piksel boyutunda RGB olarak giriş katmanında kullanılmıştır. Gelen görüntüye 3x3 boyutunda filtre kullanılarak konvolüsyon işlemi uygulanmıştır. Konvolüsyon katmanından sonra yığın normalleştirme katmanı kullanılmıştır. Çıkan veri bir sonraki katman olan sızıntı düzleştirilmiş doğrusal birim girmiştir. Normal DDB' den farklı olarak Sızıntı Düzleştirilmiş Doğrusal Birim (SDDB) ölen gradyan sorunu yaşamamaktadır, bu sayede negatif bölgedeki değerler içinde öğrenme gerçekleştirilmiştir. Bu şekilde toplam 53 adet konvolüsyon katmanı ağ yapısında bulunmaktadır. Konvolüsyon işlemleri bittikten sonra çıktıya ortalama havuzlama işlemi uygulanmıştır. Sınıflandırılmanın gerçekleştirilmesi için softmax fonksiyonu kullanılmıştır. Kullanılan ağ yapısı ek 3'te gösterilmiştir. Eğitimin mümkün olabildiğince hızlı ve iyi şekilde gerçekleştirilebilmesi için kullanılan sistem özelliklerine ve veri seti boyutuna göre optimum eğitim parametreleri seçilmiştir. Kullanılan eğitim parametreleri Tablo 13'te gösterilmiştir.

**Tablo 13. Bitişik nizam DarkNet eğitim parametreleri**

Eğitim Parametreleri	Değer
Model Adı	DarkNet53
Yığın Sayısı (Batch Size)	16
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	27800
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4461
Test Seti Sayısı	1116

Bitişik nizam bina sınıflandırma için oluşturulan veri seti hazırlanan DarkNet53 modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.1.3. SqueezeNet Mimarisi Kullanılarak Bitişik Nizam Binaların Sınıflandırılması

Kullanılan SqueezeNet mimarisinde görüntü 224x224 piksel boyutunda RGB olarak ağa giriş yapar. Giren görüntüye konvolüsyon katmanı ile 3x3 filtre boyutunda 2 adım parametresi kullanılarak konvolüsyon işlemi uygulanır. Konvolüsyon katmanından sonra DDB katmanı kullanılmıştır. DDB işlemi yapılmış veriye bir sonraki katmanda maksimum havuzlama işlemi uygulandı. Havuzlama işleminden sonra veriye tekrar 1x1 filtre boyutunda 1 adım parametresi kullanılarak konvolüsyon işlemi uygulanmıştır. Bir sonraki katman olan DDB işlemi gerçekleştirildi ve bu işlemden sonra ağ iki kola ayrılarak veriye bir kolda 3x3 ve diğer koldaki katmanda 1x1 filtre boyutunda konvolüsyon işlemi uygulanır. Kollardaki bir sonraki katmanda DDB işlemi uygulanır. Sonraki katmanda iki koldaki veriler birleştirilir. Sırası ile maksimum havuzlama ve konvolüsyon ve DDB katmanları ile işleme alınır. Bu oluşturulan katman bloğundan toplamda 10 adet kullanılmıştır. Konvolüsyon işlemi gerçekleştirilmiş veriler %50 bırakma (dropout) katmanına girmiştir. Son konvolüsyon işlemi uygulandıktan sırasıyla DDB ve maksimum havuzlama işlemleri uygulanır. Sınıflandırılmanın gerçekleştirilmesi için softmax fonksiyonu kullanılmıştır. SqueezeNet ağ yapısı detaylı olarak ekler 2 kısmında gösterilmiştir. Eğitimin mümkün olabildiğince hızlı ve iyi şekilde gerçekleştirilebilmesi için kullanılan sistem özelliklerine ve veri seti boyutuna göre optimum eğitim parametreleri seçilmiştir. Kullanılan eğitim parametreleri Tablo 14'te gösterilmiştir.

**Tablo 14. Bitişik nizam SqueezeNet eğitim parametreleri**

<b>Eğitim Parametreleri</b>	<b>Değer</b>
Model Adı	SqueezeNet
Yığın Sayısı (Batch Size)	32
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	13900
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4461
Test Seti Sayısı	1116

Bitişik nizam bina sınıflandırma için oluşturulan veri seti hazırlanan SqueezeNet modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.2. Ağır Çıkma Binaların Sınıflandırılması

Ağır çıkma binaların sınıflandırılması için VGG19, DarkNet53 ve SqueezeNet mimarileri kullanılarak 3 ayrı eğitim gerçekleştirilmiştir. Eğitilen modeller ikili sınıflandırma yapmaktadır. Veri setin de ki 4500 adet görüntünün %80 eğitim, %20 test için kullanılarak eğitimler gerçekleştirilmiştir. Kullanılan resimler 224 x 224 piksel boyutuna ağa girmektedir. Eğitimlerde kullanılan model parametreleri bitişik nizam ile aynı değerler kullanılmıştır.

##### 4.2.2.1. VGG19 Mimarisi Kullanılarak Ağır Çıkma Binaların Sınıflandırılması

Oluşturulan ağ mimarisi ile ağır çıkma eğitim seti kullanılarak eğitimler Tablo 15'teki eğitim parametreleri kullanılarak gerçekleştirilmiştir.

**Tablo 15. Ağır çıkma VGG19 eğitim parametreleri**

<b>Eğitim Parametreleri</b>	<b>Değer</b>
Model Adı	VGG19
Yığın Sayısı (Batch Size)	8
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	58900
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4715
Test Seti Sayısı	1178

Ağır çıkma bina sınıflandırma için oluşturulan veri seti hazırlanan VGG19 modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.2.2. DarkNet53 Mimarisi Kullanılarak Ağır Çıkma Binaların Sınıflandırılması

DarkNet53 ile oluşturulan ağ mimarisi ağır çıkma eğitim seti kullanılarak eğitimler Tablo 16'daki eğitim parametreleri kullanılarak gerçekleştirilmiştir.

**Tablo 16. Ağır çıkma DarkNet53 eğitim parametreleri**

<b>Eğitim Parametreleri</b>	<b>Değer</b>
Model Adı	DarkNet53
Yığın Sayısı (Batch Size)	16
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	29400
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4715
Test Seti Sayısı	1178

Ağır çıkma bina sınıflandırma için oluşturulan veri seti hazırlanan VGG19 modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.2.3. SqueezeNet Mimarisi Kullanılarak Ağır Çıkma Binaların Sınıflandırılması

SqueezeNet ile oluşturulan ağ mimarisi ağır çıkma eğitim seti kullanılarak eğitimler Tablo 17'deki eğitim parametreleri kullanılarak gerçekleştirilmiştir.

**Tablo 17. Ağır çıkma SqueezeNet eğitim parametreleri**

Eğitim Parametreleri	Değer
Model Adı	SqueezeNet
Yığın Sayısı (Batch Size)	32
Öğrenim Oranı (Learn Rate)	0.0003
Devir sayısı (Epochs)	100
İterasyon	14700
Görüntü Boyutu	224 x 224
Sınıf Sayısı	2
Eğitim Seti Sayısı	4715
Test Seti Sayısı	1178

Ağır çıkma bina sınıflandırma için oluşturulan veri seti hazırlanan SqueezeNet modelinin eğitimi gerçekleştirilmiştir.

#### 4.2.3. Sınıflandırma Metrikleri

Sınıflandırma modellerinin performansını değerlendirmek için modellerin tahmin sonuçları ile gerçek değerlerin karşılaştırılmasında hata matrisi kullanılmaktadır. Tablo 18'de ağır çıkma bina için hata matrisi gösterilmiştir. Hata matrisleri doğru pozitif (DP), yanlış pozitif (YP), yanlış negatif (YN), doğru negatif (DN) değerlerinden oluşmaktadır. doğru pozitif (DP) durumu doğruya doğru denme durumudur, doğru sınıflandırma yapıldığını gösterir. Doğru negatif (DN) yanlış pozitif denme durumudur, doğru bir sınıflandırma sonucudur. Yanlış negatif (YN), yanlış pozitif denme durumudur, yanlış bir sınıflandırma sonucudur. Yanlış pozitif (YP) doğruya yanlış denme durumudur, başarısız bir sınıflandırmadır. Hata matrisi kullanılarak sınıflandırma sonuçlarının değerlendirme metrikleri hesaplanmıştır. Tez çalışmasında eğitilen modellerin sınıflandırma işlemlerinin başarımını değerlendirmek için 6 adet sınıflandırma metrikleri kullanılmıştır. Kullanılan metrikler doğruluk, özgüllük, kesinlik, duyarlılık, F1 puanı ve geometrik ortalamadır.

**Tablo 18. Ağır çıkma bina için hata matrisi**

		Var olan Durum	
		Pozitif Durumlar (Ağır çıkma var)	Negatif Durumlar (Ağır çıkma yok)
Tahmin	Pozitif (Ağır çıkma var)	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif (Ağır çıkma yok)	Yanlış Negatif (YN)	Doğru Negatif (DN)

#### 4.2.3.1. Doğruluk

Doğruluk metriği yapılan tahminlerin yüzde kaçının doğru olduğunu gösterir. Doğruluk metriğini hesaplamak için doğru sınıflandırma sayısını, toplam sınıflandırma sayısına bölerek bulunur.

$$\text{Doğruluk} = \frac{DN + DP}{\text{TOPLAM}}$$

(2)

#### 4.2.3.2. Özgüllük

Özgüllük metriği negatif durumunun ne kadar olduğunu gösterir. Özgüllük metriğini hesaplamak için doğru negatif sayısının doğru negatif ile yanlış pozitif sayılarının toplamına bölünerek bulunur.

$$\text{Özgüllük} = \frac{DN}{(DN + YP)}$$

(3)

#### 4.2.3.3. Kesinlik

Kesinlik metriği doğru olarak yapılan sınıflandırmaların gerçekte kaç adedinin doğru olduğunu gösterir. Kesinlik metriğini hesaplamak için doğru pozitiflerin doğru pozitif ile yanlış pozitiflerin toplamına bölünür.

$$\text{Kesinlik} = \frac{DP}{(DP + YP)}$$

(4)

#### 4.2.3.4. Duyarlılık

Duyarlılık metriđi pozitif olarak sınıflandırılması gereken tahminlerin ne kadarının pozitif olarak tahmin edildiđini göstermektedir. Duyarlılık metriđi hesaplamak için doğru pozitif sayısı, doğru pozitif ve yanlış negatife bölünerek bulunur.

$$Duyarlılık = DP / (DP + YN)$$

(5)

#### 4.2.3.5. F1 Puanı

F1 Puanı kesinlik ve duyarlılık deđerlerinin harmonik ortalamasını vermektedir.

$$F1 = 2 \times \frac{kesinlik \times duyarlılık}{kesinlik + duyarlılık}$$

(6)

#### 4.2.4. Grad-CAM ile Isı Haritasının Oluřturulması

Grad-CAM Sınıflandırma işleminin hangi görüntünün hangi bölgesindeki çıkartılan özniteliklere göre karar verdiđini göstermektedir. Karar aşamasında karar en etkili olan öznitelikten daha az olan özniteliđe göre bir ısı haritası oluşturulmuřtur.

İlk adım olarak aktivasyon haritalarındaki deđişimi bulmak için aktivasyon haritalarının ařađdaki denklem 2 ile gradyanını hesaplanmıřtır.  $y^{logit}$  softmax öncesi sınıf skor deđerini göstermektedir.  $F^n$  n adet özellik haritasını temsil etmektedir.

$$\frac{\partial y^{logit}}{\partial F^n} \quad (2)$$

İkinci adımda aktivasyon haritalarının model tahmini için önem dercesine göre, sıralamak amacıyla denklem 3 ile maksimum havuzlama işlemi uygulanmıřtır.  $Y$  deđeri yüksekliđi temsil etmektedir.  $G$  deđeri geniřliđi temsil etmektedir.

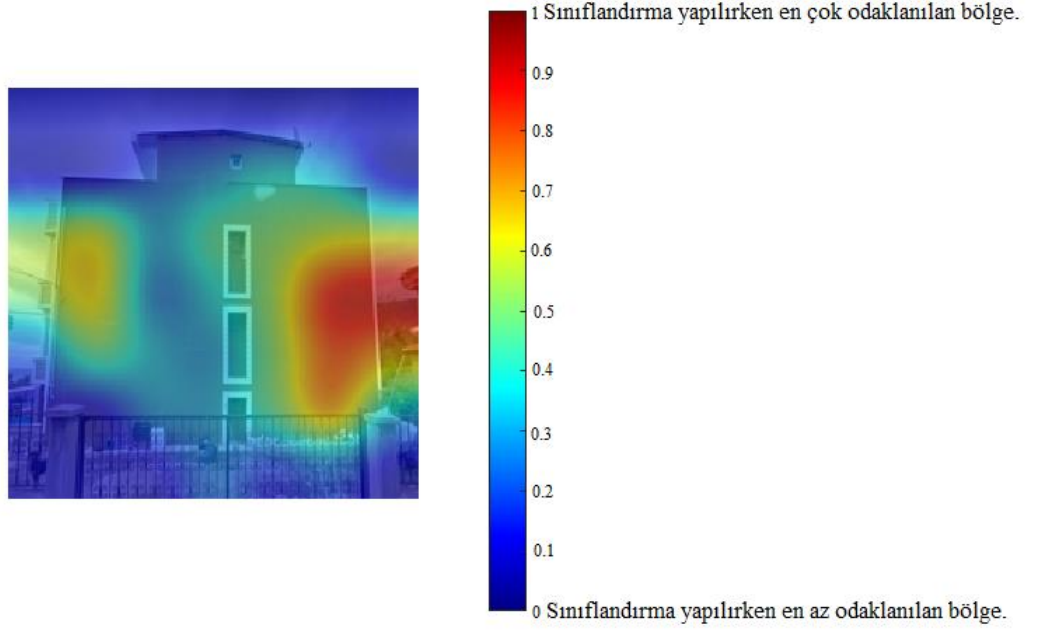
$$\alpha_k^{logit} = \frac{1}{Y.G} \sum_i \sum_j \frac{\partial y^{logit}}{\partial F^n}$$

(3)

Son adımda elde edilen ağırlıklar ile aktivasyon haritasının ağırlık kombinasyonu alınarak istenilen sonuca ulaşılmıştır. Negatif değerlerden kurtulmak için düzleştirilmiş doğrusal birim işlemi uygulanmıştır.

$$L_{Grad-CAM}^{logit} = \text{Re } LU\left(\sum_n \alpha_n^{logit} \cdot F^n\right)$$

(4)



Şekil 20. Isı haritası renk barı




## 5. BULGULAR VE TARTIŞMA

### 5.1. Bitişik Nizam Binaların Sınıflandırma Sonuçları

#### 5.1.1. Bitişik Nizam Binaların VGG19 Eğitim Sonuçları

Eğitim süreci Şekil 21’de verilen grafikte gösterilmiştir. Grafikte iterasyonlardaki doğruluk oranı verilmiştir. Eğitimin sonuçları Tekil 21’de gösterilmiştir.



**Şekil 21. Bitişik nizam VGG19 eğitim süreci**

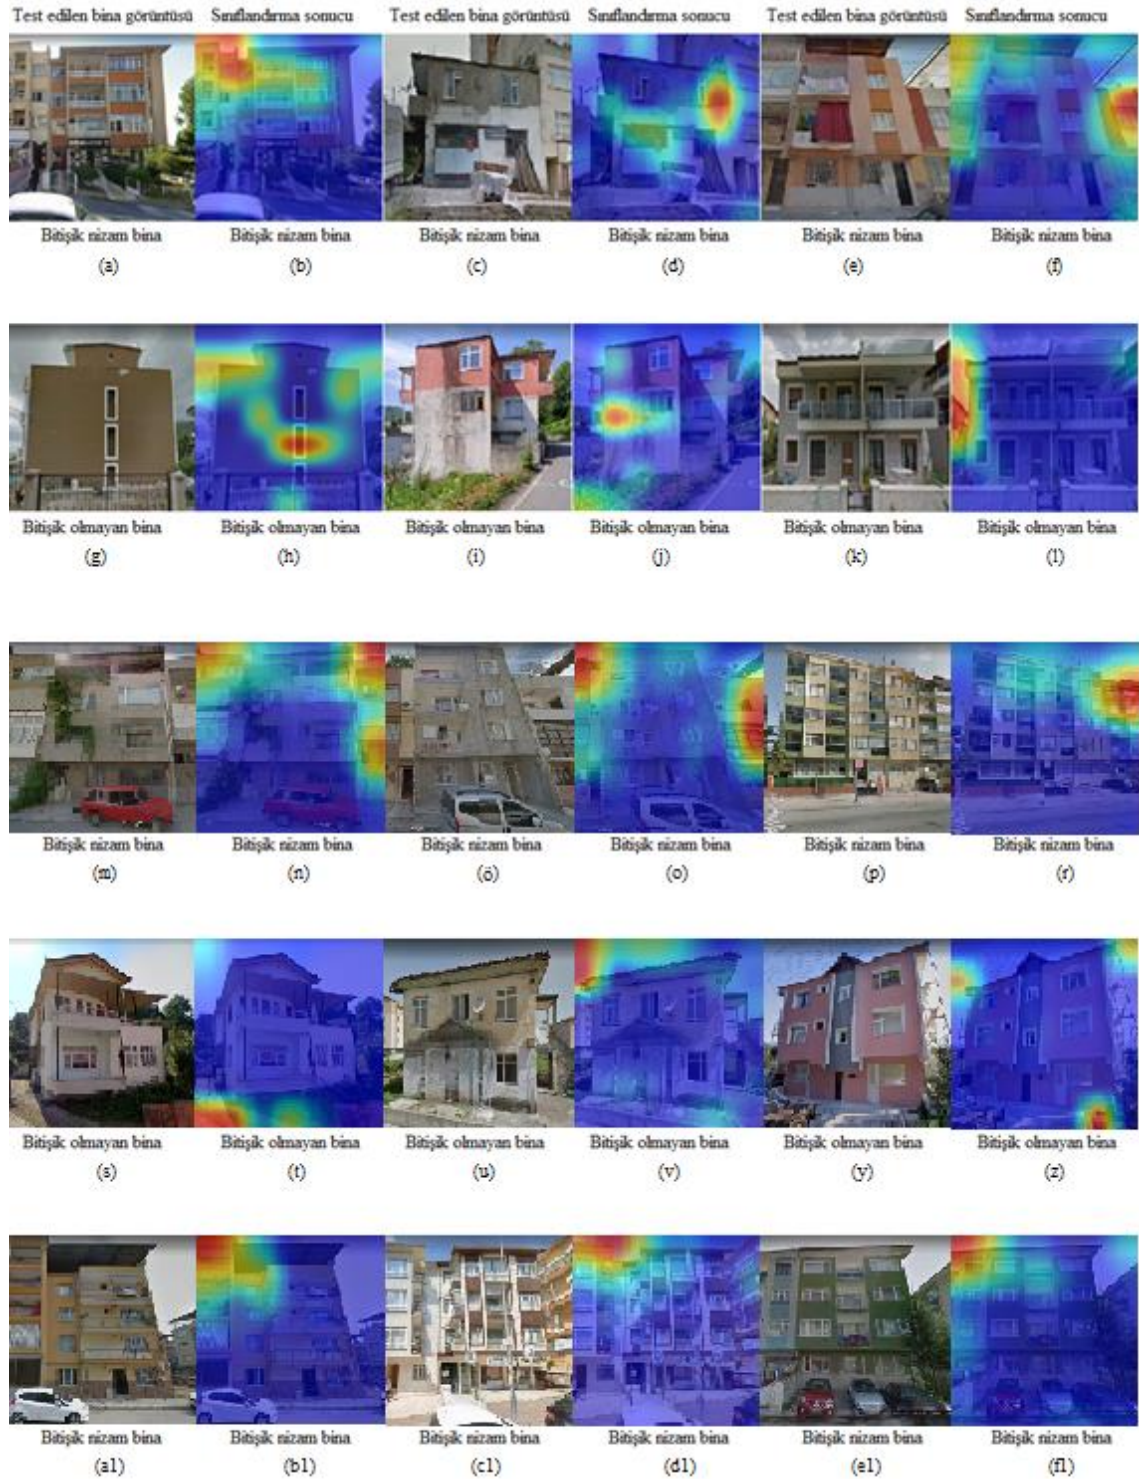
Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş model kullanılarak test edilmiştir. Doğruluk oranı, özgüllük, kesinlik, duyarlılık, F1 puanı, ve geometrik ortalama Tablo 19’da gösterilmiştir. Test edilen resimler ısı haritalı sonuçları ile sonuçları değerlendire bilmek için kaydedilmişlerdir.

**Tablo 19. Bitişik nizam VGG19 eğitim sonuçları**

Sınıf	VGG19 bitişik nizam eğitim sonuçları						Eğitim süresi
	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	
Bitişik Bina		0.9577	0.9344	0.9582	0.9462	0.9580	
Bitişik Olmayan Bina	95.79%	0.9582	0.9733	0.9577	0.9654	0.9580	311 dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere göre karar verdiğini gösteren

bir ısı haritası test edilen görsellere uygulandı. Şekil 22’de teste giren bina cephe resimleri, sınıflandırma sonuçları ve ısı haritası ile verilmiştir.




Şekil 22. Bitişik nizam VGG19 test görüntüleri

Eğitimin başarımı ve sınıflandırma yapılırken algoritmanın resmin hangi kısma baktığı değerlendirildiği zaman VGG19 eğitimin başarılı olduğu görülmüştür. Test edilen resimler ve ısı haritaları detaylı bir şekilde incelenmiştir. Algoritma yüksek oranda (%95,7) doğru sınıflandırma yapmıştır. VGG19 sonucunun ısı haritaları incelendiğinde karar vermek için birinci ve ikinci bitişik olmayan bina testlerinde, binanın orta noktalarına odaklanmalar görülmektedir. Bitişik nizam durumunun tespiti için binanın sağ ve sol kısımlarına odaklanması gerekmektedir. Odaklanma noktaları doğru olsa da yeterince iyi odaklanamadığı görülmektedir. VGG19 ağının derinliğinin yeterli öğrenme için daha yetersiz olduğu görülmüştür. Şekil 22 (f)'de iki cepheden bitişik nizam olan binanın, bitişik cephelerine doğru bir şekilde odaklandığı görülmüştür.

### 5.1.2. Bitişik Nizam Binaların DarkNet53 Eğitim Sonuçları

Eğitim süreci Şekil 23'te ki grafikte gösterilmiştir. Grafik her bir iterasyondaki öğrenme durumunu göstermektedir. Algoritmanın eğitim sürecinde sınıflandırma sırasında doğruluk yüzdeleri eğitimin başarılı bir şekilde gerçekleştirdiğini bize göstermektedir. Grafik üzerinde eğitim sürecindeki iterasyonlardaki sınıflandırma sonucunun gerçek değere ne kadar uzak olduğunu gösteren hata değeri bulunmaktadır.



**Şekil 23. Bitişik nizam DarkNet53 eğitim süreci**

Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş model kullanılarak teste tabi tutulmuştur. Doğruluk oranı ve eğitim süresi Tablo 19'de gösterilmiştir. Teste

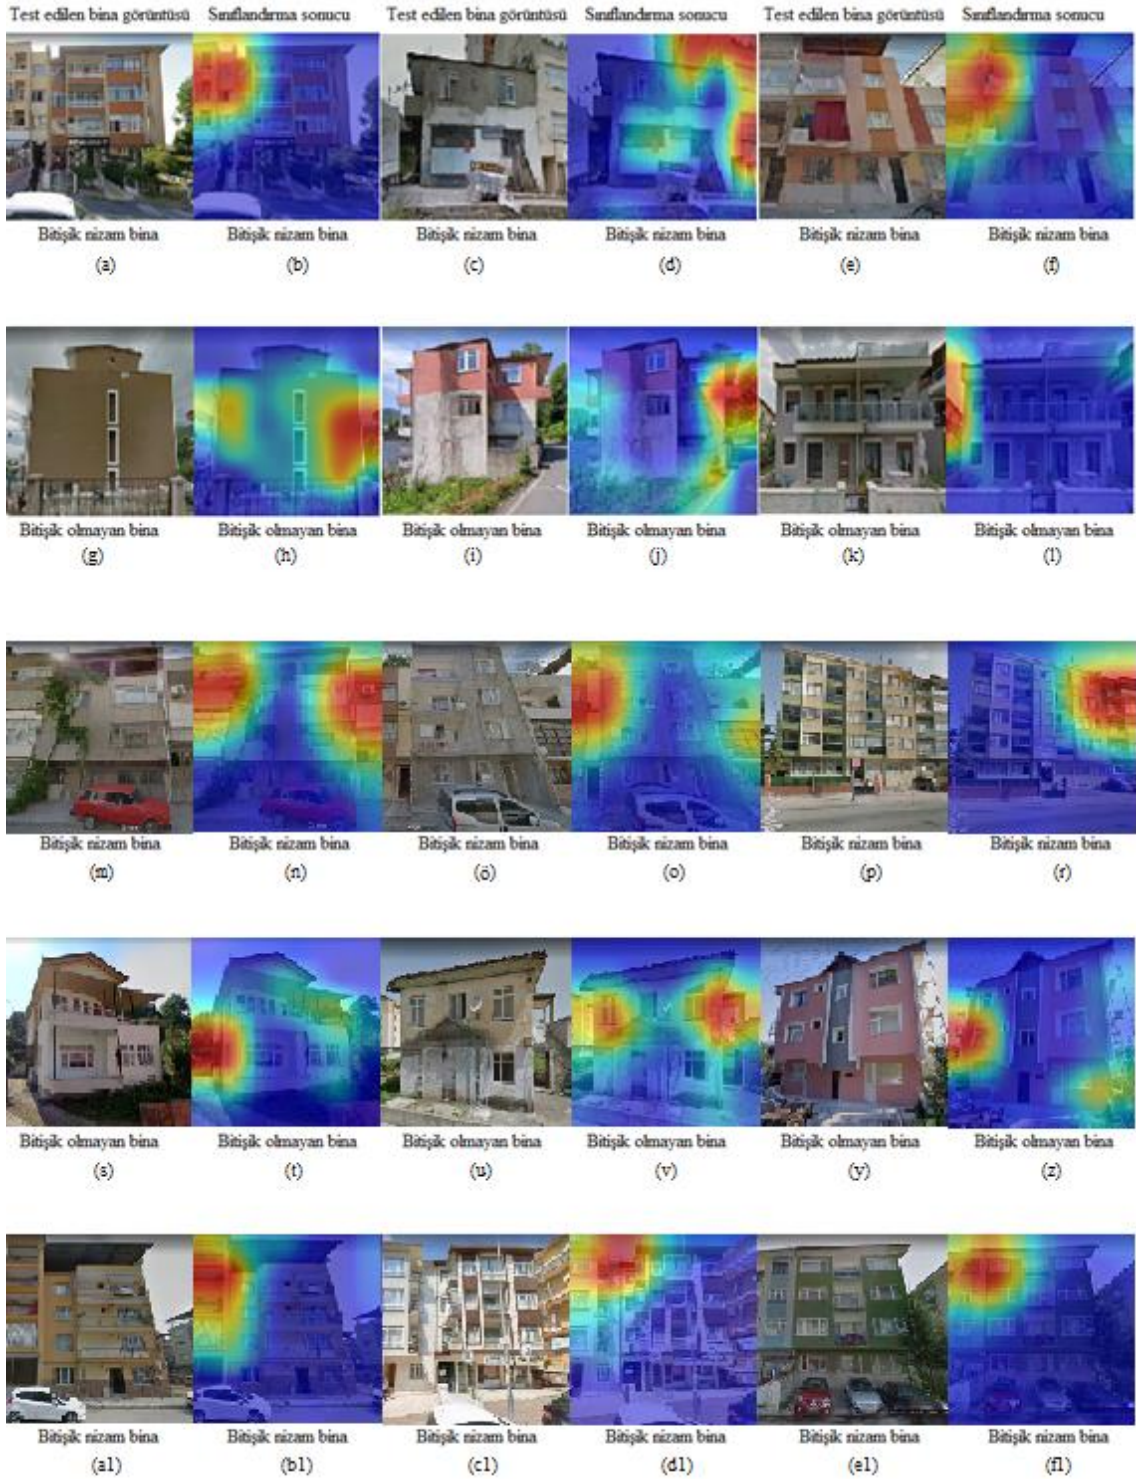
giren bina cephe görüntüleri ve aynı resim üzerine ısı haritası uygulanmış bir şekilde birleştirilerek sonuç resimleri oluşturulmuştur. Bu şekilde resmin orijinal haline bakılarak ısı haritasının eklenmiş bina cephe resminin değerlendirilmesi pratik hale getirilmiştir. Oluşturulan bu test çıktısı görselinde, teste giren bina cephe resminin üzerine resmin etiketi ve diğer üzerine ısı haritası eklenmiş olan görselin üzerine sınıflandırma sonucu yerleştirilmiştir.

**Tablo 20. Bitişik nizam DarkNet53 eğitim parametreleri**

DarkNet53 Bitişik nizam eğitim sonuçları							
Sınıf	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	Eğitim süresi
Bitişik Bina		0.9752	0.9603	0.9536	0.9569	0.9643	343
Bitişik Olmayan Bina	96.68%	0.9536	0.9709	0.9752	0.9731	0.9643	dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere odaklanarak karar verdiğini gösteren bir ısı haritası test edilen görsellere uygulanmıştır. Isı haritalarında mavi bölgeden kırmızı bölgeye göre alanın sınıflandırma ne kadar etkili olduğunu göstermektedir. Kırmızı bölge karar vermek için en çok odaklanan bölgeyi temsil ederken mavi bölgeler en az odaklanan bölgeyi temsil etmektedir. Şekil 24'te hazırlanan bu test çıktı resimleri gösterilmiştir.






**Şekil 24. Bitişik nizam DarkNet53 test görüntüleri**

Eğitimin başarımı ve ısı haritası algoritmanın resmin hangi kısma bakarak karar verdiği değerlendirildiği zaman DarkNet53 eğitimin başarılı olduğu görülmüştür. Algoritma en yüksek oranda (%96,68) doğru sınıflandırmayı gerçekleştirmiştir. Diğer algoritmalar arasında en iyi performansı veren algoritmadır. DarkNet53 odaklandığı noktalara ısı

haritalarından bakıldığında binanın sağ ve sol kısımlarına odaklandığı görülmektedir. Şekil 24'te gösterilen birinci bitişik olmayan bina sonucuna bakıldığında, odaklanmanın binanın sağ ve sol kısımlarına iyi bir şekilde gerçekleştirildiği görülmüştür. Şekil 24 (n)' de iki cepheden de bitişik binada, bitişik olan cephelere doğru bir şekilde odaklanıldığı görülmüştür. DarkNet53 mimarisinin kullandığımız sınıflandırma yeterli için yeterli derinlikte ve özelliklerde olduğu görülmüştür. DarkNet53 eğitiminin başarılı olduğu çıkan sonuçlardaki odaklanmanın ne kadar iyi olmasından görülmektedir. Binaların karar vermesi için gerekli olan bölgelerine odaklanmıştır. Diğer algoritma sonuçlarına bakıldığı zaman odaklanmaların DarkNet53 kadar başarılı olmadığı görülmüştür.

### 5.1.3. Bitişik Nizam Binaların SqueezeNet Eğitim Sonuçları

Eğitim süreci Şekil 25'te ki grafikte gösterilmiştir. Grafikte iterasyonlardaki doğruluk oranı verilmiştir. Grafik incelendiği zaman iterasyonlar ilerledikçe hata değerinin arttığı gözlemlenmiştir. Hata değerinin artması öğrenim sürecinin sağlıklı bir şekilde gelişmediği göstermektedir. Eğitimin düzgün bir şekilde gerçekleşmemesine rağmen doğruluk oranının yüksek çıkması sadece doğruluk oranına bakılarak sınıflandırmanın doğru yapıldığını anlaşılamayacağını bize göstermektedir. Algoritma tesadüf olarak doğru sonuçlar verebilmektedir. Bu sebeple algoritmanın bina cephe görüntüsünün hangi bölgesine odaklandığını gösteren ısı haritalarının kullanım gerekliliği görülmüştür.



Şekil 25. Bitişik nizam SqueezeNet eğitim süreci

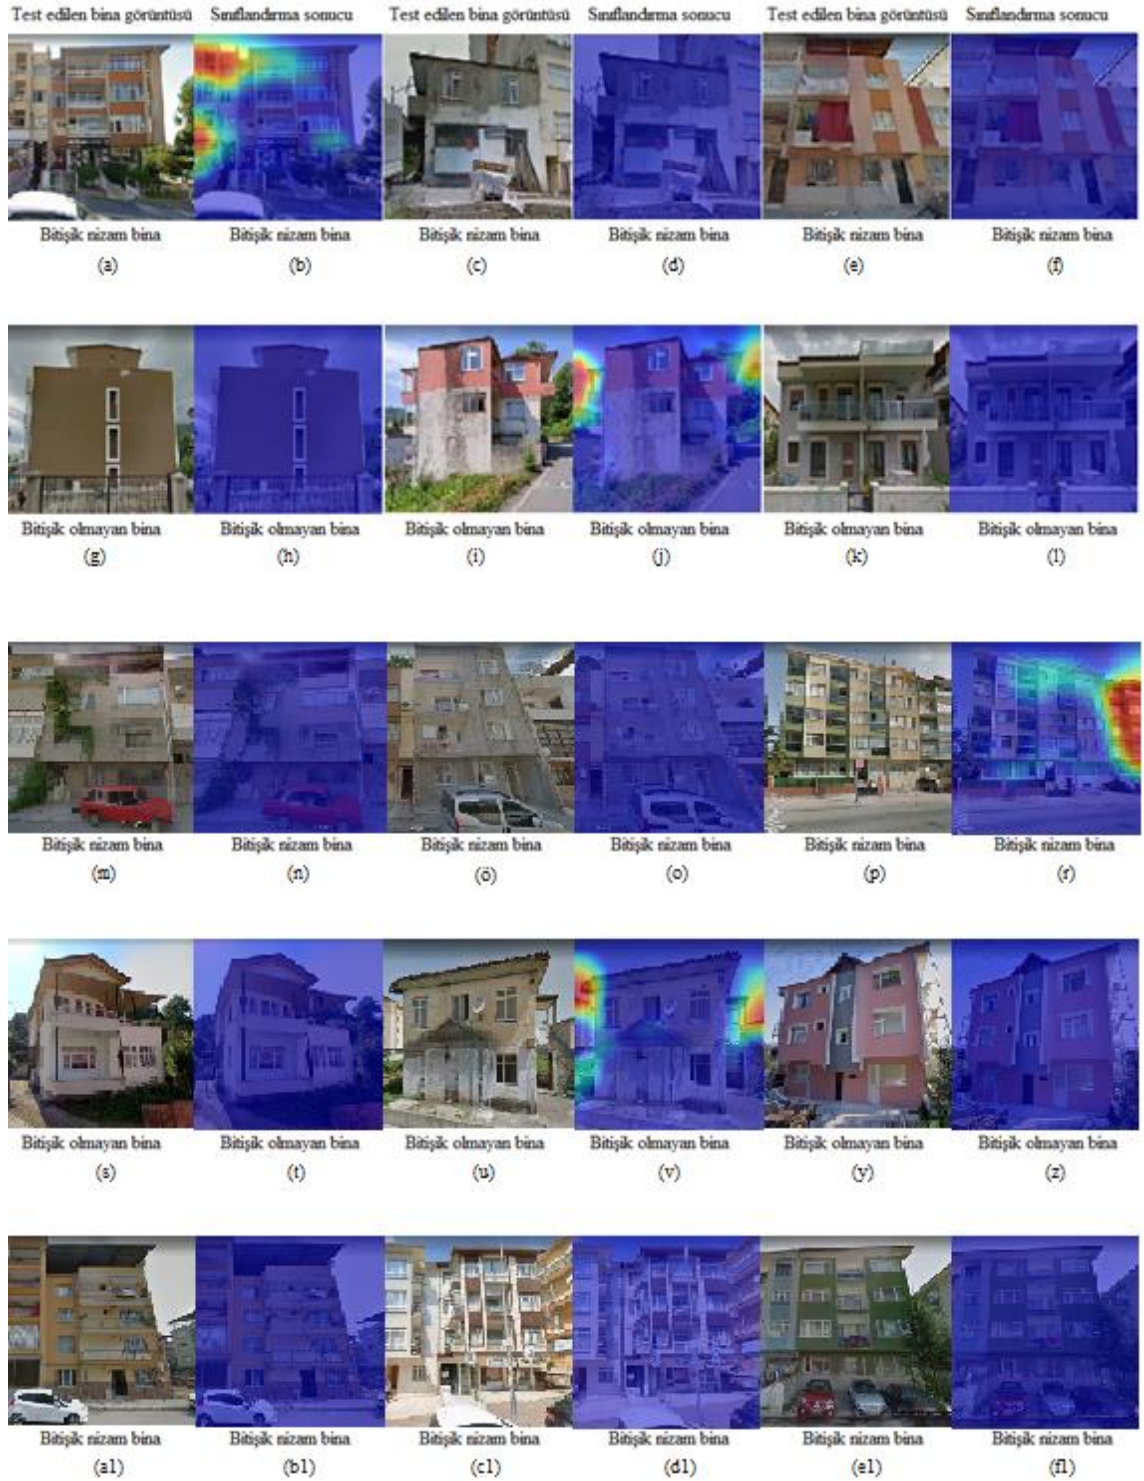
Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş modele sokulmuştur. Doğruluk oranı Tablo 21’de gösterilmiştir. Eğitimin başarılı geçmemesine rağmen doğruluk oranları çok yüksek çıkmıştır. Hata değer grafiği incelendiği zaman 20. İterasyondan sonra hata değeri artmaya başlandı görülmüştür. Hata değeri artış gösterirken doğruluk oranı 90% değerlerine ulaşmaktadır. Model eğitim seti üzerinde aşırı öğrenme gerçekleştirerek ezberleme yapmıştır. Aşırı öğrenme sonucunda yüksek doğruluk yakalansa da sağlıklı bir eğitim gerçekleşmemiştir. Bu durumun önüne geçmek için daha fazla veri ekleme veya düzenleme işlemi uygulanabilir.

**Tablo 21. Bitişik nizam SqueezeNet eğitim sonuçları**

SqueezeNet bitişik nizam eğitim sonuçları							
Sınıf	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	Eğitim süresi
Bitişik Bina		0.9752	0.9584	0.9095	0.9333	0.9418	97
Bitişik Olmayan Bina	94.98%	0.9095	0.9448	0.9752	0.9598	0.9418	97 dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere göre karar verdiğini gösteren bir ısı haritası test edilen görsellere uygulanmıştır. Şekil 25’te teste giren bina cephe resimleri, sınıflandırma sonuçları ve ısı haritası ile verilmiştir. Şekilde bulunan bina cephe görüntüleri bitişik nizam durumu ve bitişik nizam olmama şeklinde iki adet sınıflandırma test sonuç görüntüsü bulunmaktadır. Sınıflandırma işlemi tesadüfen doğru çıktığı görülmektedir.





**Şekil 26. Bitişik nizam SqueezeNet test görüntüleri**

Sonuçlar incelendiği zaman SqueezeNet başarımlarının yüksek (94.98%) olarak yüksek başarımlar gösterse de ısı haritaları incelendiği zaman algoritmanın doğru noktalara bakarak karar vermediği görülmüştür. Bu sebeple algoritmanın yaptığı sınıflandırmalar doğru olsa eğitim başarısız olmuştur. SqueezeNet sınıflandırma yaparken




odaklanmadığı Şekil 26’da (d), (f) ve (t)’de görülmektedir. Aynı resimlerde VGG19 ve DarkNet53 sınıflandırma sonuçlarına bakıldığında aradaki fark bariz bir şekilde görülmektedir. SqueezeNet ağ yapısı istenilen sınıflandırmayı yapmak için yetersiz kalmıştır.

## 5.2. Ağır Çıkma Binaların Sınıflandırma Sonuçları

### 5.2.1. Ağır Çıkma Binaların VGG19 Eğitim Sonuçları

Eğitim süreci Şekil 27’de ki grafikte gösterilmiştir. Grafikte iterasyonlardaki doğruluk oranı ve hata değeri verilmiştir.



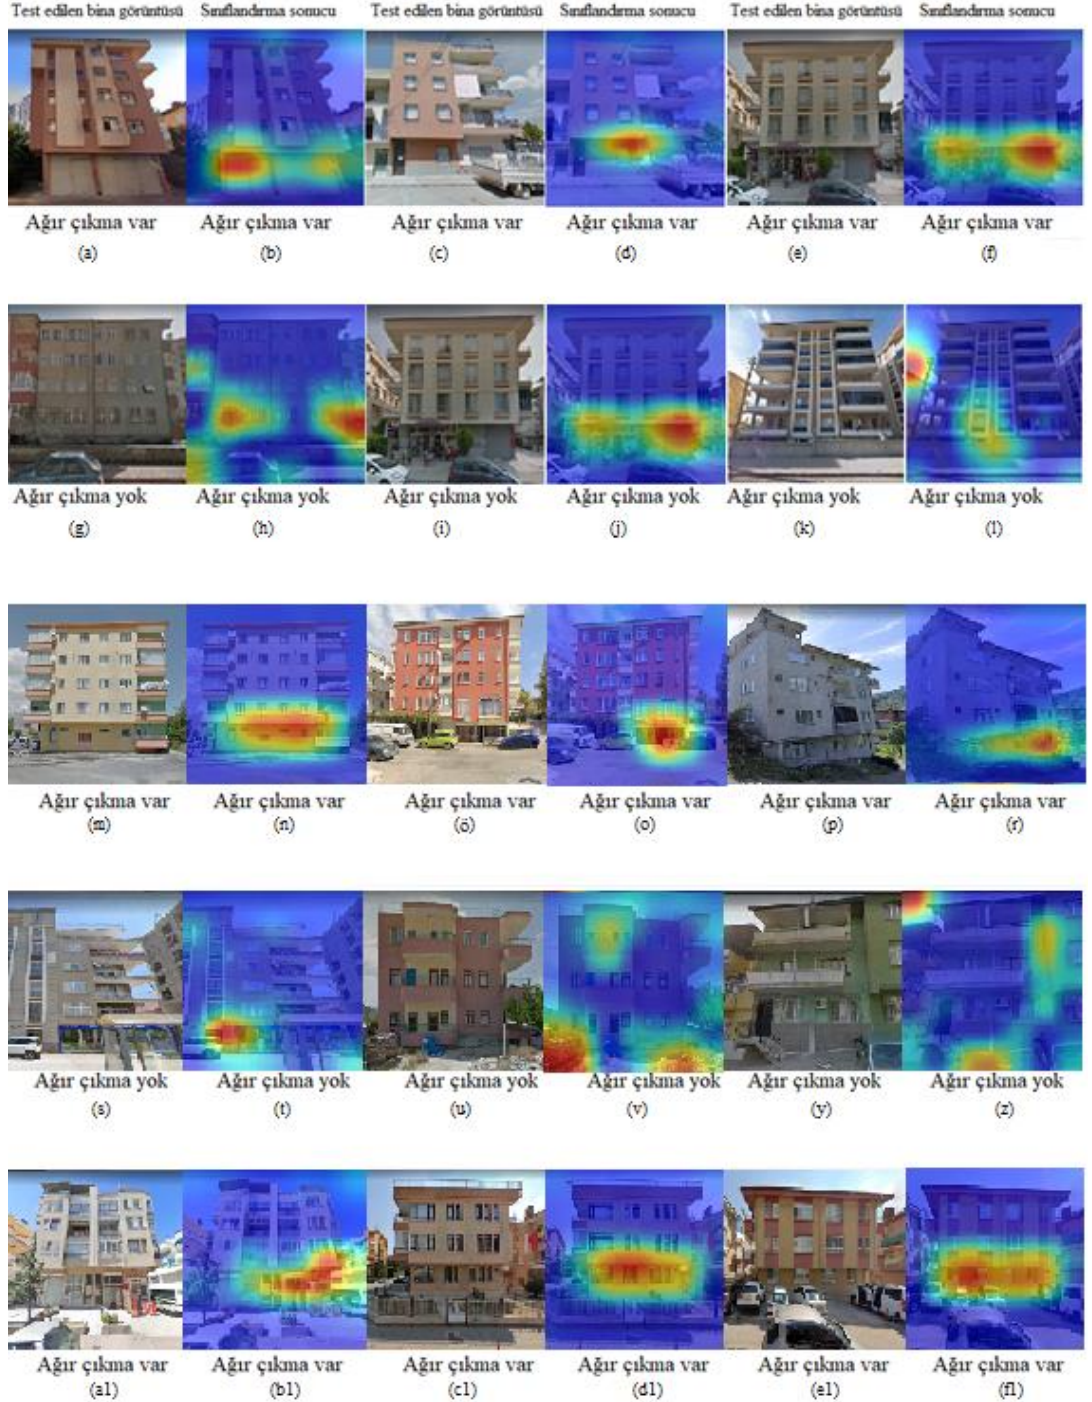
Şekil 27. Ağır çıkma VGG19 eğitim süreci

Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş modele sokulmuştur. Doğruluk oranı Tablo 21’de gösterilmiştir.

Tablo 22. Ağır çıkma VGG19 eğitim sonuçları

VGG19 ağır çıkma eğitim sonuçları							
Sınıf	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	Eğitim süresi
Ağır Çıkma Var	87.01%	0.8276	0.8545	0.9082	0.8806	0.8670	330
Ağır Çıkma Yok		0.9082	0.8900	0.8276	0.8577	0.8670	dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere göre karar verdiğini gösteren bir ısı haritası test edilen görsellere uygulandı. Şekil 28’de teste giren bina cephe resimleri, sınıflandırma sonuçları ve ısı haritası ile verilmiştir. Sınıflandırıcı resmin doğru noktalarına odaklanarak karar vermiştir.

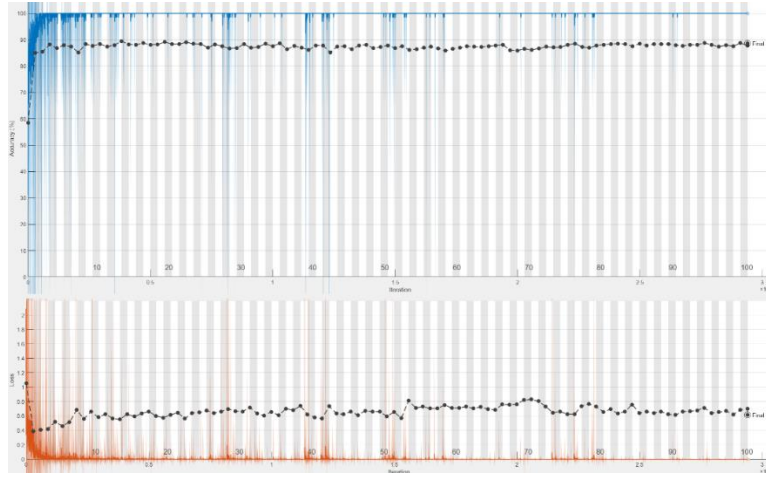


Şekil 28. Ağır çıkma VGG19 test görüntüleri

VGG19 eğitimi yüksek başarılı olarak gerçekleşmiştir. Şekil 28’de (b), (d) ve (o)’ da sınıflandırıcının odaklandığı noktalar doğru olsa da yeterince odaklanmadığı görülmektedir. Diğer örneklere bakıldığı zamanda benzer durum gözlemlenmektedir. Bu durum algoritmanın öğrendiğini fakat yeterince öğrenmediği göstermektedir. VGG19 ağ yapısının daha sığ olmasından dolayı öğrenim işlemi yetersiz kalmıştır. Sınıflandırıcı %87 başarımla göstermesi bu durumu desteklemektedir.

### 5.2.2. Ağır Çıkma Binaların DarkNet53 Eğitim Sonuçları

Eğitim süreci Şekil 29’da ki grafikte gösterilmiştir. Grafikte iterasyonlardaki doğruluk oranı verilmiştir.



**Şekil 29. Ağır çıkma DarkNet53 eğitim süreci**

Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş modele sokulmuştur. Doğruluk oranı Tablo 23’te gösterilmiştir.

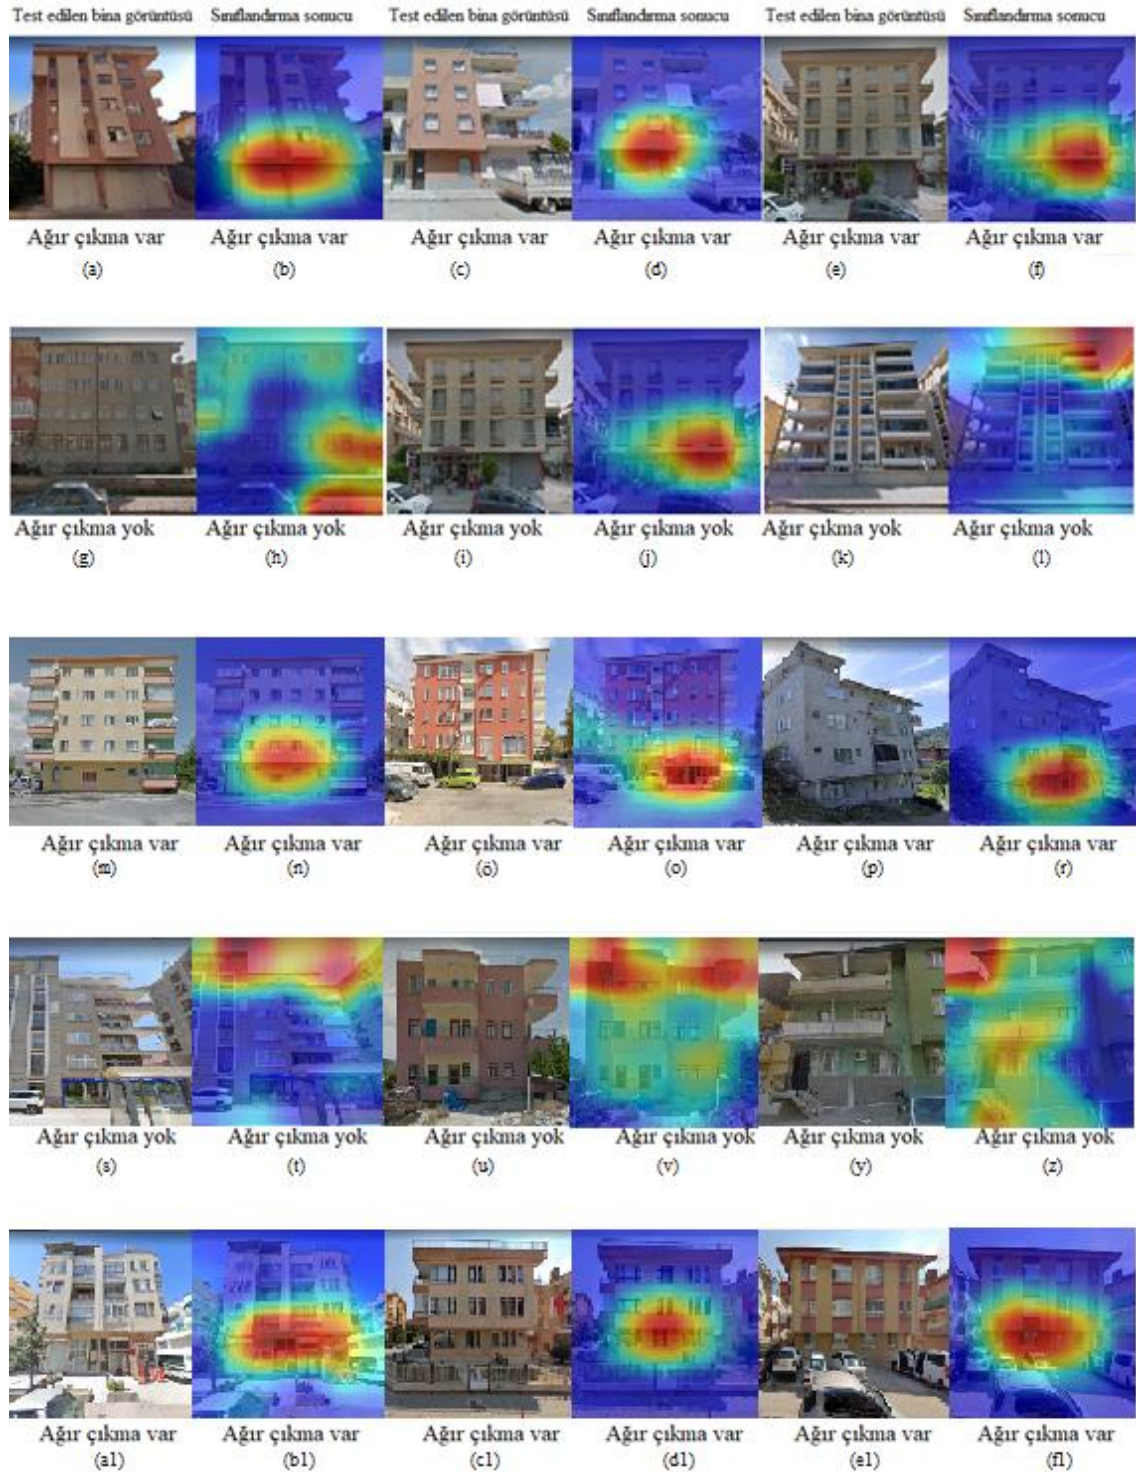
**Tablo 23. Ağır çıkma DarkNet53 eğitim sonuçları**

DarkNet53 ağır çıkma eğitim sonuçları							
Sınıf	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	Eğitim süresi
Ağır Çıkma Var	88.62%	0.8636	0.8811	0.9066	0.8937	0.8848	328
Ağır Çıkma Yok		0.9066	0.8924	0.8636	0.8777	0.8848	dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere göre karar verdiğini gösteren



bir ısı haritası test edilen görsellere uygulandı. Şekil 30'da teste giren bina cephe resimleri, sınıflandırma sonuçları ve ısı haritası ile verilmiştir.

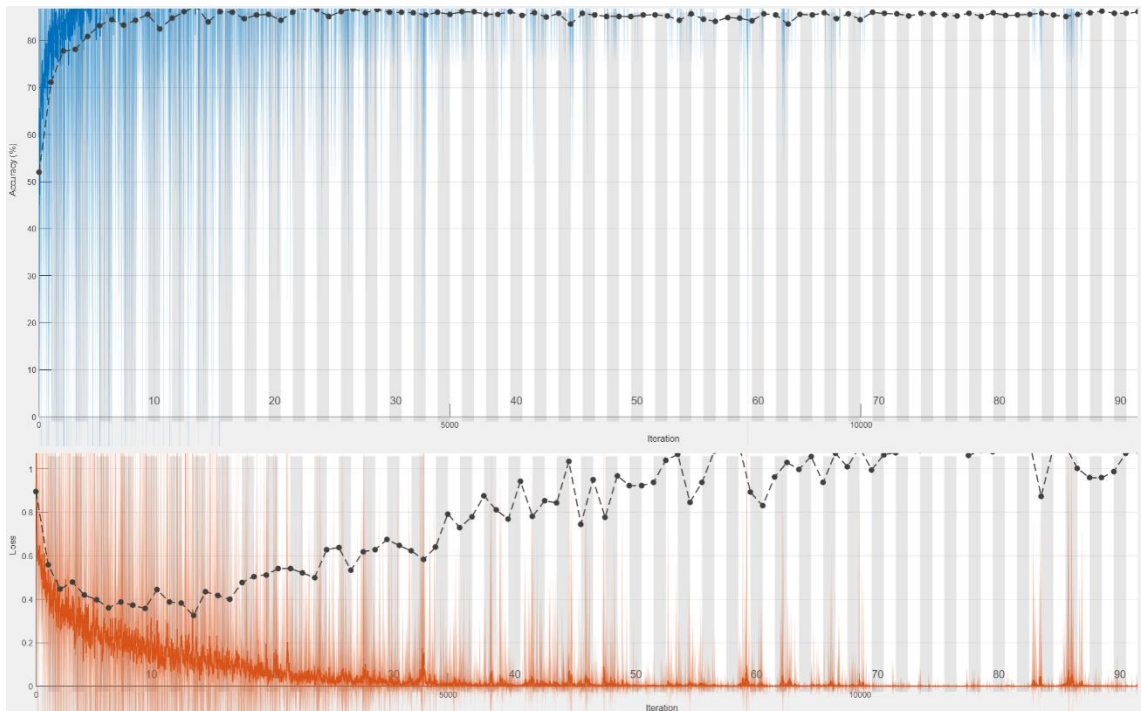


Şekil 30. Ağır çıkma DarkNet53 test görüntüleri

Test sonuçları incelendiğinde başarımların yüzdesine ve sınıflandırmak için resmin hangi noktalarına odaklanarak karar verdiği bakıldığı zaman en iyi sonucu DarkNet53 mimarisi vermiştir. Isı haritaları incelendiğinde DarkNet53 modeli Şekil 30 (b)'de iyi bir şekilde odaklansa da (h) ve (l)'de odakta resmin dışına taşma olmuştur. VGG19'dan 88% doğruluk oranı ile daha yüksek başarımlar gösterse de eğitim sürecinin bazı çok iyi olmadığı görülmektedir. Şekil 30 (b), (o), (r) ve (b1)'deki ısı haritaları incelendiği zaman sınıflandırıcının doğru noktalara odaklandığı görülmektedir. Sınıflandırıcı bazı hatalarda bulursa da genel olarak doğru noktalara odaklanmıştır.

### 5.2.3. Ağır Çıkma Binaların SqueezeNet Eğitim Sonuçları

Eğitim süreci Şekil 31'de ki grafikte gösterilmiştir. Grafikte iterasyonlardaki doğruluk oranı verilmiştir. Yapılan eğitim başarılı olmamıştır.



**Şekil 31. Ağır çıkma SqueezeNet eğitim süreci**

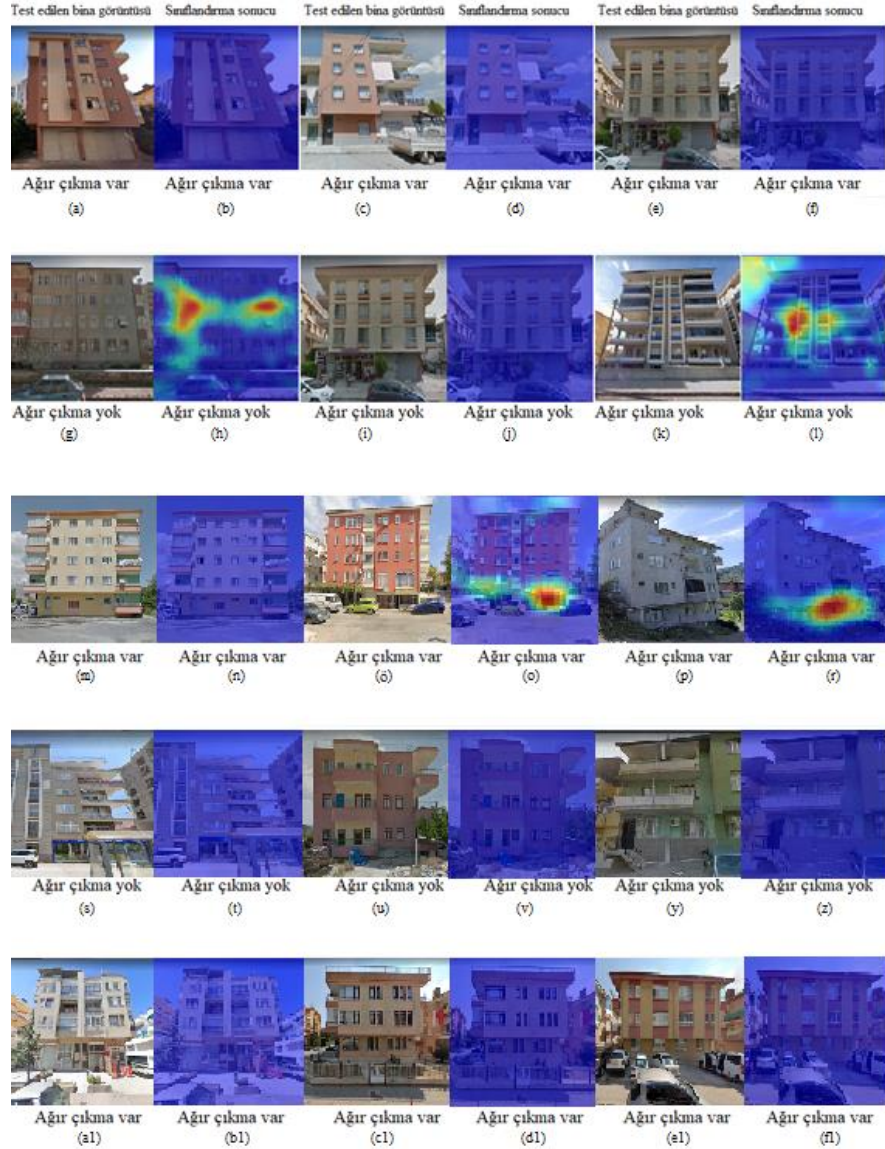
Grafik incelendiği zaman hata değerinin 10'nuncu iterasyondan sonra ciddi oranda arttığı görülmüştür. Eğitimlerin başarımlarını ölçmek için ayrılan test veri seti eğitilmiş modele sokulmuştur. Doğruluk oranı Tablo 24'te gösterilmiştir. Eğitim grafiği ve sonuçlar incelendiği zaman aşırı öğrenme durumunun gerçekleştiği görülmektedir. Aşırı

öğrenme durumunun önüne geçmek için veri çoğaltma ve düzenleme işlemleri uygulanabili

**Tablo 24. Ağır çıkma SqueezeNet eğitim sonuçları**

SqueezeNet ağır çıkma eğitim sonuçları							
Sınıf	Doğruluk	Özgüllük	Kesinlik	Duyarlılık	F1 puanı	Geometrik ortalama	Eğitim süresi
Ağır Çıkma Var	85.40%	0.7935	0.8306	0.9082	0.8677	0.8489	102
Ağır Çıkma Yok		0.9082	0.8858	0.7935	0.8371	0.8489	dakika

Eğitimin doğruluk oranının dışında eğitimin doğru gerçekleştiğini test etmek için sınıflandırılan resimlerin hangi bölgelerindeki özelliklere göre karar verdiğini gösteren bir ısı haritası test edilen görsellere uygulandı. Şekil 32’de teste giren bina cephe resimleri, sınıflandırma sonuçları ve ısı haritası ile verilmiştir.



**Şekil 32. Ağır çıkma SqueezeNet test görüntüleri**

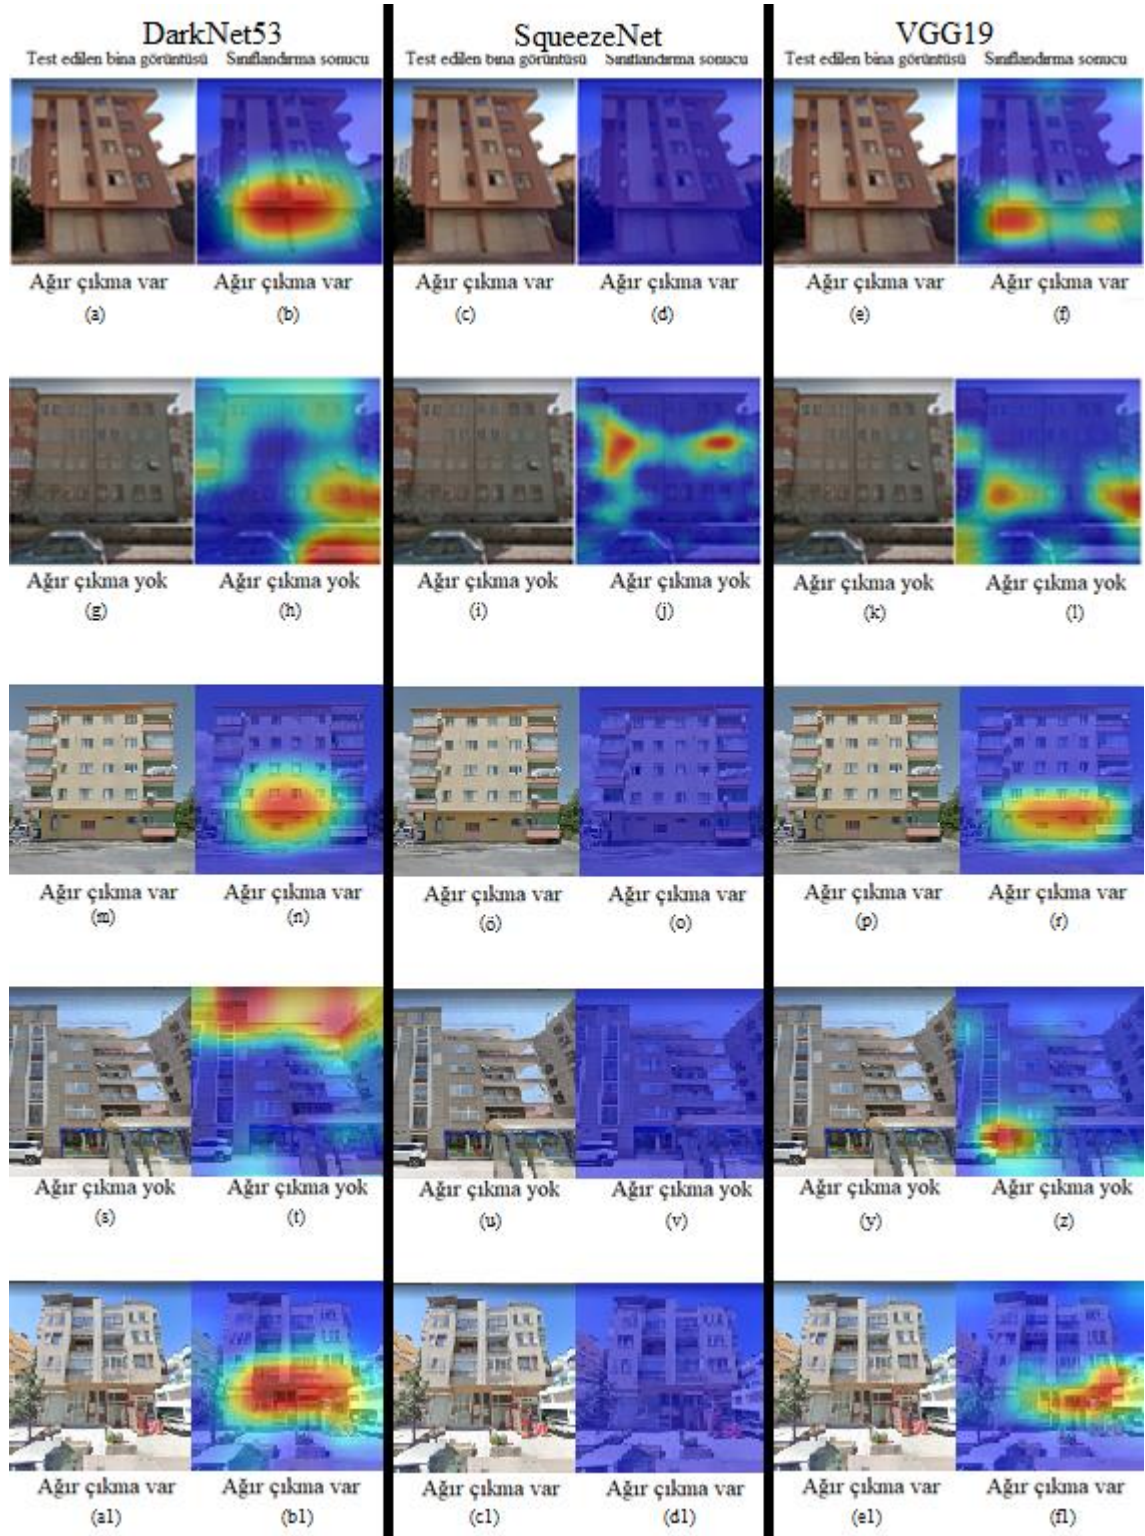
SqueezeNet yüksek doğruluk oranında (85.40%) sonuç vermiştir. Fakat ısı haritaları incelendiği zaman algoritmanın odaklanamadığı tespit edilmiştir. Şekil 31 ağır çıkma var örneklerinde algoritmanın hiçbir noktaya odaklanmadığı görülmüştür. SqueezeNet modelinin eğitiminin başarısız olduğu Şekil 31 (b), (d) ve (f) ısı haritalarında ilgisiz noktalara odaklanmasından görülmüştür.

### 5.3. Sonuçların Karşılaştırılması

Bitişik nizam ve ağır çıkma binaların otomatik sınıflandırılma başarılı bir şekilde sağlanmıştır. Eğitimler SqueezeNet dışındaki modeller ile başarılı bir şekilde tamamlanmıştır. Ağır çıkma binalar için en iyi sonucu DarkNet53 mimarisi ile eğitilen



model vermiştir. Şekil 33'te ağır çıkma sınıflandırma için teste giren bina resimleri gösterilmiştir.



Şekil 33. Ağır çıkma test sonuçları karşılaştırma



Ağır çıkma sınıflandırma için yapılan eğitimlerin başarımlarını yüzde karşılaştırılması Tablo 25’te verilmiştir. En iyi sonucu DarkNet53 modeli verirken VGG19 modeli de çok iyi bir başarımlar göstererek doğru bir sınıflandırma yapmıştır. Şekil 33 (b), (d) ve (f) sıcaklık haritaları karşılaştırıldığı zaman DarkNet53 model sonucu olan (b)’nin açık ara daha iyi odaklandığı görülmüştür. SqueezeNet modeli yüksek başarımlar oranına sahip olsa da ısı haritaları üzerinden resmin hangi noktasına odaklanarak karar verdiği kontrol edildiği zaman eğitimin başarısız olduğu görülmüştür.

**Tablo 25. Ağır çıkma KSA modelleri doğruluk oranı karşılaştırması**

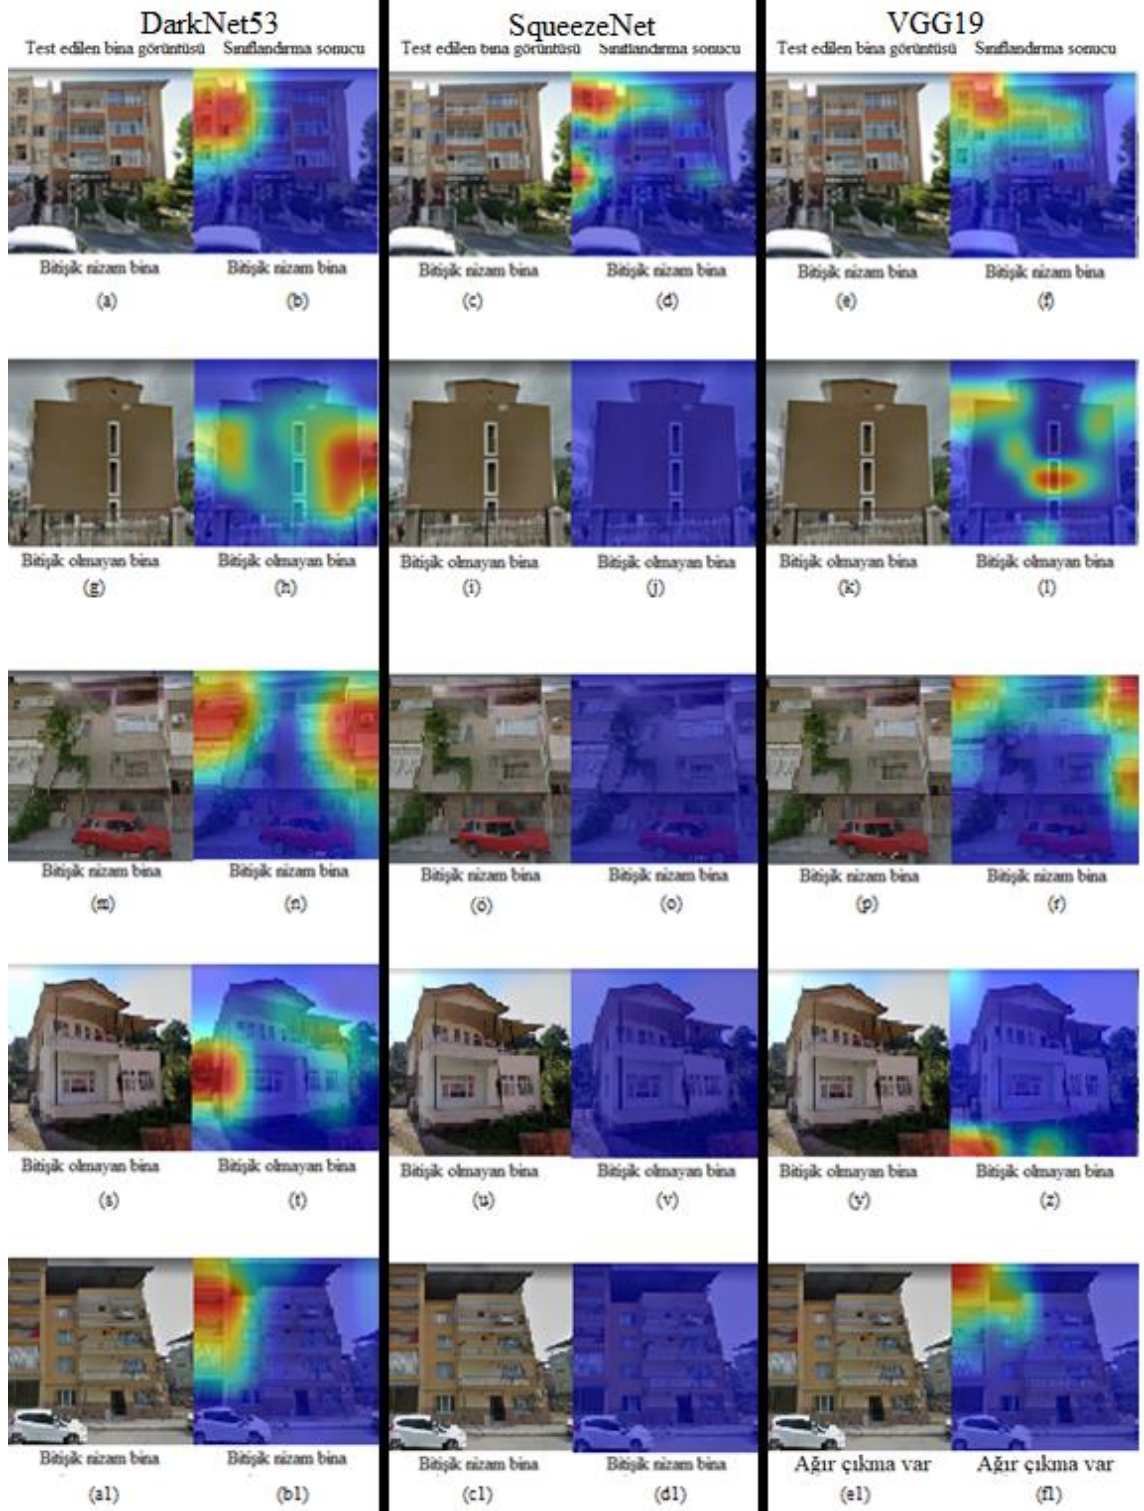
<b>Eğitim Sonuçları</b>	<b>Değer</b>		
Model Adı	DarkNet53	SqueezeNet	VGG19
Sınıf Adı	Ağır Çıkma	Ağır Çıkma	Ağır Çıkma
Doğruluk	88.62%	85.40%	87.01%

Bitişik nizam binalar için en iyi başarımlarını DarkNet53 mimarisi ile eğitilen model göstermiştir. Tablo 26’da bitişik nizam sınıflandırma için teste giren bina cephe görsellerinin sonuçlarının karşılaştırılması gösterilmiştir.

**Tablo 26. Bitişik nizam KSA modelleri doğruluk oranı karşılaştırması**

<b>Eğitim Sonuçları</b>	<b>Değer</b>		
Model Adı	DarkNet53	SqueezeNet	VGG19
Sınıf Adı	Bitişik Nizam	Bitişik Nizam	Bitişik Nizam
Doğruluk	96.68%	94.98%	95.79%

Şekil 34’te bitişik nizam sınıflandırma için teste giren bina resimlerinin sonuçları karşılaştırılmıştır. Şekil 34 (n), (o) ve (f) sıcaklık haritaları incelendiğinde DarkNet53 model sonucu olan (n)’nin daha başarılı odaklandığı görülmüştür.



Şekil 34. Bitişik nizam test sonuçları karşılaştırma

## 6. SONUÇ

Türkiye'nin bulunduğu coğrafi konum ve Türkiye'de maalesef çeşitli nedenlerden dolayı mühendislik hizmeti almamış, yaptıkları yıl geçerli olan deprem yönetmeliğine uygun imal edilmemiş betonarme binaların sayıca çok olmasından dolayı olası bir orta-şiddetli depremde hasar alacak veya yıkılacak riskli bina sayısı çoktur. Bu binaları depreme dayanıklı hale getirilmesi veya yıkılması, can ve mal kayıplarını önlemek açısından hayati önem taşımaktadır. Sayıca çok olan bu binaların öncelikle hızlı bir risk analizi ile risk önceliklerine göre ayıklanması, çok riskli olanların detaylı bir analiz ile yıkılması yada güçlendirilmesi hayati önem taşımaktadır. Bu nedenle deprem açısından riskli binaların tespiti alınacak önlemler için başlangıç adımını oluşturmaktadır. Binaların depreme dayanıklılık durumunun tespiti için detaylı performans analizleri gerekmektedir ve bu maddi ve zaman açısından külfetli bir süreçtir. Bu sebeplerden dolayı hangi binanın daha öncelikli, depreme dayanıklılık durumunun tesbitinin yapılması için hızlı değerlendirme yöntemleri ile binaların risk öncelik durumlarının tespiti yapılmaktadır. Tespitin yapılabilmesi için bir konu üzerinde uzman kişinin değerlendirmeyi yapması gerekir.

Tez çalışmasının amacı hızlı değrelendrimе metodun da değrelendirme için kullanılan parametrelerden bitişik nizam bina durumu ve ağırçıkma bina durumun otomatik olarak bina cephe görüntüleri üzerinden tespit edebilen bir algoritma geliştirilmesidir. Bu parametrelerin otomatik olarak tespiti, binaların risk önceliği tespitinde gerekli olan uzmana olan ihtiyacı azaltarak insandan kaynaklacak hataları, harcanan zamanı, ve maddiyatı azaltarak fayda sağlamaktadır.

Tez çalışmasında kullanılan algoritmanın oluşturulmasında yapay zekâ yöntemlerinden biri olan derin öğrenme kullanılmıştır. KSA ile sınıflandırıcı algoritma oluşturulmuştur. Sınıflandırıcımızın eğitilmesi farklı ön eğitilmiş KSA'lar kullanılarak sınıflandırma başarımları karşılaştırılmıştır. Kullanılan ön eğitilmiş KSA'lar VGG19, SqueezeNet ve DarkNet53 modelleridir. Eğitim sonucunda sınıflandırma işlemi başarı ile gerçekleşmiştir. Bitişik nizam binaların sınıflandırılmasında en iyi başarımları (96.68%) DarkNet53 göstermiştir. Ağır çıkma binaların sınıflandırılmasında en iyi başarımları (88.62%) DarkNet53 göstermiştir. SqueezeNet her iki sınıflandırma için yüksek başarımlar versede bina üzerinden karar vermek için hangi bölgelere odaklandığına bakıldığı

zaman eğitimin başarılı olmadığı görülmüştür. SqueezeNet eğitim sonuçlarının yüksek doğruluk oranlı olsada sınıflandırma işlemini doğru bir şekilde yapamaması, doğruluk oranlarının tek başına eğitimin başarısını ölçmede yeterli olmadığını göstermiştir.

Bu tez çalışmasında hızlı görsel tarama analizin de değerlendirme kriteri olarak kullanılan parametrelerden bitişik nizam olma ve ağır çıkma olma durumlarının tespiti uzman mühendis olmadan görüntü işleme kullanılarak derin öğrenme sınıflandırıcı ile parametrelerin durumunun tespit edilmesi sağlanmıştır. Bu sayede bu iki parametrenin tespitinde insan kaynaklı hataların, zaman ve maddi kayıpların oluşmasını önlemek amaçlanmıştır.

Hızlı değerlendirme parametrelerinden ağır çıkma ve bitişik nizam parametrelerinin bina cephe görüntüleri üzerinden otomatik tespiti ile literatürde herhangi bir çalışma yapılmamıştır. Yapılan çalışma konu üzerindeki ilk çalışmadır. Gelecek çalışmalarda hızlı değerlendirme yönteminin diğer parametrelerinin de otomatik tespiti yapılarak değerlendirme süreci tamamen otomatik hale getirebilir. Bu sayede deprem performans analizi için risk önceliği belirleme süresi daha kısa hale getirilebilir. İnsan faktörünün ortadan kalkması ile insandan dolayı oluşabilecek hataların ve yorum farklarından dolayı oluşacak problemlerin önüne geçerek belli bir standartın gelmesi sağlanabilir.

Sonuç olarak 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. Bu tez çalışması kapsamında yer alan iki parametrenin haricinde risk analizine yapıların cephe görüntüsü ve planlarına bağlı olarak elde edilecek olan diğer parametrelerinde derin öğrenmeye gibi akıllı yazılımlarla tespit edilebileceği görülmektedir. Gelecek çalışmalarda da diğer parametreler göz önüne alınarak akademik çalışmalar yapılabilir. Özellikle bu çalışmanın temelinde olan (Arslan, Yaravariabdı, Doğan, Ekici, & Aşık, 2021) tarafından patent başvurusu yapılmış olan ‘‘Konut Türü Binaların Deprem Risk Önceliklerinin Tespitinde Kullanılan Geometrik Parametrelerin Evrişimli Sinir Ağları ile Belirlenmesi Yöntemi’’ sağlanabilir. adlı çalışma ile de önümüzdek yıllarda bu açığın doldurulması hedeflenmektedir.

## KAYNAKLAR

- 6306 sayılı Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun (2012). Ankara: Yayımlı, 15/12/2012 tarihli ve 28498 sayılı Resmî Gazete.
- Adha, A., Pamuncak, A., Qiao, W., & Laory, I. (2022). Automated building classification framework using convolutional neural network, Cogent Engineering, Volume 9, 2022.
- Arslan, M. H., Yavariabdi, 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>.
- Assessment and Improvement of the Structural Performance of Buildings in Earthquakes (2006). New Zealand Society for Earthquake Engineering. NZSEE Study Group on Earthquake Risk Buildings, New Zealand.
- Bal, İ. E., Tezcan, S.S., & Gülay, F. G. (2007). Betonarme Binaların Göçme Riskinin Belirlenmesi İçin P25 Hızlı Değerlendirme Yöntemi, Altıncı Ulusal Deprem Mühendisliği Konferansı, İstanbul.
- Bal, İ.E., ve Özdemir, Z. (2006). Çevre Çerçeve Kirişi Süreksizliğinin Yapı Deprem Davranışı Üzerindeki Etkileri, İ.M.O. İstanbul Bülten, Sayı: 87.
- Bengio, Y., Courville, A., Vincent, P., (2013). Representation learning: A review and new perspectives. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 35 (8), 1798–1828.
- Çelik, E., Atalay, M., & Bayer, H. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri ile Deprem Tahmininde Sismik Darbelerin Kullanılması.
- Deng, L., & Yu, D. (2014). Deep Learning: Methods and Applications, Found. Trends® Signal Process., vol. 7, no. 3–4, pp. 197–387, 2014.
- E. Damcı., B. Yıldızlar, G. Gürsoy, N. K. Özturun, & T. Çelik (2003). “Bakırköy Özelinde, Türkiye Genelinde Yapı Durum Tespiti İçin Bir Algoritma”, Beşinci Ulusal Deprem Mühendisliği Konferansı, İ.T.Ü. Süleyman Demirel Kültür Merkezi, İstanbul.

- FEMA 154 (2015). Rapid Visual Screening of Buildings for potential seismic hazards: A Handbook, Federal Emergency Management Agency, Washington DC, USA.
- 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.
- Florido E., J. L. Aznarte, A. Morales-Esteban, & F. Martínez Álvarez (2016). Earthquake magnitude prediction based on artificial neural networks: A survey, Croatian Operational Research Review, vol. 7(2), pp. 159- 169.
- Fukushima K. N. (1980). A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position., Biol. Cybern., vol. 36, no. 4, pp. 193–202.
- Geng, R., Ma, Y., & Huang, W. (2020). An improved helmet detection method for YOLOv3 on an unbalanced dataset, Dalian.
- Gonzalez, D., Rueda-Plata, D., Acevedo, A.B., Duque, J.C., Ramos-Pollán, R., Betancourt, A., & García, S. (2020). Automatic detection of building typology using deep learning methods on street level images, Building and Environment, Volume 177.
- Gürbüz, A. & Tekin, M. (2017). Farklı Tip Betonarme Binalar İçin Geliştirilmiş Hasar Tahmin Yöntemleri, Teknik Dergi.
- He, K. M., Zhang, X. Y., Ren, S. Q., & Sun, J. (2016). Deep Residual Learning for Image Recognition. 2016 Ieee Conference on Computer Vision and Pattern Recognition (Cpvr): 770-778.
- 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 model size, 3th International Conference on Learning Representations. Toulon: ICLR;2016. pp.1-13, 2016.
- Integrated Rapid Visual Screening of Buildings for Seismic Hazard (2014). 1nd ed. Gurgaon, India, Taru.
- Ivakhnenko, A. G., & Lapa, V. G. (1966). Cybernetic Predicting Devices, 1966.

- Kdnuggets (2017). Neural Network Foundations, Explained: Activation Function, <https://www.kdnuggets.com/2017/09/neural-network-foundations-explained-activation-function.html>. Erişim tarihi: 6 Haziran 2022
- Kim, Kwang Gi. (2016). Deep Learning, Biomedical Engineering Branch Division of Precision Medicine and Cancer Informatics, PhD, National Cancer Center, Goyang, Korea.
- Kotsiantis, S.B., Zaharakis, I.D., & Pintelas, P.E. (2006). Machine learning: A review of classification and combining techniques, *Artif. Intell. Rev.* 26 159–190.
- Krizhevsky, A., Sutskever, I., & Hinton G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks, in *Advances in neural information processing systems*, pp. 1097–1105.
- Manual for Screening of Buildings for Seismic Investigation (1992). Institute for Research in Construction National Research Council Canada. Ottawa, Canada.
- Mathwork (2020). What is a convolutional neural network?, <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>. Erişim tarihi: 01 Haziran 2022
- Mertol, H. C., Tunc, G., & Akis, T. (2021). Damage Observation of Reinforced Concrete Buildings after 2020 Sivrice (Elazığ) Earthquake, *Journal of Performance of Constructed Facilities* vol. 35.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview, *Neural Networks*, vol. 61, pp. 85–117.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization, 2017 IEEE International Conference on Computer Vision (ICCV), 2017, pp. 618-626, doi: 10.1109/ICCV.2017.74.
- Shrestha, B., & Hong, H. (2018). Building Pounding Damages Observed during the 2015 Gorkha Earthquake, *Journal of Performance of Constructed Facilities*, vol.32.

- Standard for Seismic Evaluation of Existing Reinforced Concrete Buildings (2001).  
Japan Building Disaster Prevention Association.Tokyo, Japan.
- Sucuođlu, H. (2007). Kentsel Yapı Stoklarında Deprem Risklerinin Sokaktan Tarama Yöntemi ile Belirlenmesi, Altıncı Ulusal Deprem Mühendisliği Konferansı, İstanbul.
- Szegedy, C., Liu, W., Jia, Q. Y., 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., & Wojna, Z. (2016) Rethinking the inception architecture for computer vision, in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2818-2826, 2016.
- Tezcan, S., Bal, İ. E., Özdemir, Z., & Küçük, F. (2005). Depremde “Sıfır” Can Kaybı Nasıl Sağlanır?, Şantiye İnşaat Makina ve Mimarlık Dergisi, Sayı:232, Syf:108-112.
- Türk Bina Deprem Yönetmeliđi (2018). Afet ve Acil Durum Yönetimi Başkanlığı.
- Yu, Q., Wang, C., McKenna, F., Yu, S. X., Ertugrul Taciroglu, Barbaros Cetiner, Kincho H Law (2020). Rapid visual screening of soft-story buildings from street view images using deep learning classification, Building and Enviroment vol. 19, pp. 827-838.
- Zeiler, M. D., & Fergus, R. (2014). "Visualizing and Understanding Convolutional Networks." Computer Vision - Eccv 2014, Pt I 8689: 818-833.



## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

Adı Soyadı :Fuat YALINIZ

### EĞİTİM DURUMU

Lisans Öğrenimi :2018, KTO Karatay Üniversitesi Mekatronik,  
Mühendisliği

Bildiği Yabancı Diller :İngilizce

### İŞ DENEYİMİ

Stajlar :2016, Stajer, TÜMAŞ

Çalıştığı Kurumlar :2020, Ar-Ge Mühendisi, MEPSAN Petrol Cihazları.

Tarih: 29 Ağustos 2022

# EK 1. FEMA 154 BİNA DEĞERLENDİRME FORMU

## Rapid Visual Screening of Buildings for Potential Seismic Vulnerability

FEMA-154/ATC-21 Based Data Collection Form

(Seismic Zones IV & V)

	Address: .....		Ward no. ....		
	ID.....				
	No. Stories .....		Year Built.....		
	Surveyor..... Date.....				
	Owner Name.....				
	Building Name.....				
	Use .....				
	Current Visual Condition		Excellent <input type="checkbox"/>	Good <input type="checkbox"/>	Damaged <input type="checkbox"/>
			Distressed <input type="checkbox"/>		
	PHOTOGRAPH (or specify photograph numbers)				
Comments:					
Plan and Elevation Scale					
		ROOF TYPE		EASY ACCESS	
		Lintel	Sloping Tin	Yes      No	
Occupancy		SOIL TYPE (IS 1893-2002)		FALLING HAZARDS	
(Peak) (Low)		Max. Number of Persons 0-10      11-100 101-1000    1000+			
Assembly	Govt.	Office	Max. Number of Persons 0-10      11-100 101-1000    1000+	Type I Hard Soil	
Commercial	Historic	Residential			Type II Medium Soil
Emer. Service	Industrial	School		Type I Soft Soil	
			Chimneys	Parapets	
			Cladding	Other	

### BASIC SCORE, MODIFIERS, AND FINAL SCORE,S

Building Type	Wood	S1 (FRAME)	S2 (LM)	C1 (MRF)	C2 (SW)	C3 (INF)	URM (BAND)	URM 2	URM 3
<b>Basic Score</b>	3.8	2.8	3.2	2.5	2.8	2.6	2.8	1.8	1.4
Mid Rise (4 to 7 stories)	N/A	+0.2	N/A	+0.4	+0.4	+0.2	+0.4	-0.2	-0.4
High Rise (>7 stories)	N/A	+0.6	N/A	+0.6	+0.8	+0.3	N/A	N/A	N/A
Vertical Irregularity	-2.0	-1.0	N/A	-1.5	-1.0	-1.0	-1.0	-1.0	-1.0
Plan Irregularity	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5
Code Detailing	N/A	+0.4	N/A	+0.2	+1.4	+0.2	N/A	N/A	N/A
Soil Type II	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4
Soil Type III	-0.8	-0.6	-0.6	-0.6	-0.6	-0.4	-0.6	-0.6	-0.6
Poor condition	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5

### FINAL SCORE, S

Result Interpretation (Likely building performance)

S < 0.3	High probability of Grade 5 damage; Very high probability of Grade 4 damage	Further Evaluation Recommended  Yes    No.
0.3 < S < 0.7	High probability of Grade 4 damage; Very high probability of Grade 3 damage	
0.7 < S < 2.0	High probability of Grade 3 damage; Very high probability of Grade 2 damage	
2.0 < S < 3.0	High probability of Grade 2 damage; Very high probability of Grade 2 damage	
S > 3.0	Probability of Grade 1 damage	

\*=Estimated, subjective, or unreliable date  
DNK= Do Not Know

FRAME= Steel Frame  
INF= Burnt Brick Masonry Infill Wall  
MRF= Moment-Resisting Frame  
FD= Flexible Diaphragm

SW= Shear Wall  
LM= Light Metal  
BAND= Seismic Band  
URM3= Unreinforced masonry (lime mortar)

URM2= Unreinforced burnt brick or stone masonry (cem mortar)  
RD= Rigid diaphragm

## EK 2. SQUEEZENET AĞ YAPISI

	Name	Type	Activations	Learnables
1	<b>data</b> 224×224×3 images with 'zero-center' normalization	Image Input	224×224×3	-
2	<b>conv1</b> 64 3×3×3 convolutions with stride [2 2] and padding [0 0 0 0]	Convolution	111×111×64	Weights 3×3×3×64 Bias 1×1×64
3	<b>relu_conv1</b> ReLU	ReLU	111×111×64	-
4	<b>pool1</b> 3×3 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	55×55×64	-
5	<b>fire2-squeeze1x1</b> 16 1×1×64 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	55×55×16	Weights 1×1×64×16 Bias 1×1×16
6	<b>fire2-relu_squeeze1x1</b> ReLU	ReLU	55×55×16	-
7	<b>fire2-expand1x1</b> 64 1×1×16 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	55×55×64	Weights 1×1×16×64 Bias 1×1×64
8	<b>fire2-expand3x3</b> 64 3×3×16 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	55×55×64	Weights 3×3×16×64 Bias 1×1×64
9	<b>fire2-relu_expand1x1</b> ReLU	ReLU	55×55×64	-
10	<b>fire2-relu_expand3x3</b> ReLU	ReLU	55×55×64	-
11	<b>fire2-concat</b> Depth concatenation of 2 inputs	Depth concatenation	55×55×128	-
12	<b>fire3-squeeze1x1</b> 16 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	55×55×16	Weights 1×1×128×16 Bias 1×1×16
13	<b>fire3-relu_squeeze1x1</b> ReLU	ReLU	55×55×16	-
14	<b>fire3-expand3x3</b> 64 3×3×16 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	55×55×64	Weights 3×3×16×64 Bias 1×1×64
15	<b>fire3-relu_expand3x3</b> ReLU	ReLU	55×55×64	-
16	<b>fire3-expand1x1</b> 64 1×1×16 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	55×55×64	Weights 1×1×16×64 Bias 1×1×64
17	<b>fire3-relu_expand1x1</b> ReLU	ReLU	55×55×64	-
18	<b>fire3-concat</b> Depth concatenation of 2 inputs	Depth concatenation	55×55×128	-
19	<b>pool3</b> 3×3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	27×27×128	-
20	<b>fire4-squeeze1x1</b> 32 1×1×128 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	27×27×32	Weights 1×1×128×32 Bias 1×1×32
21	<b>fire4-relu_squeeze1x1</b> ReLU	ReLU	27×27×32	-
22	<b>fire4-expand1x1</b> 128 1×1×32 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	27×27×128	Weights 1×1×32×128 Bias 1×1×128
23	<b>fire4-expand3x3</b> 128 3×3×32 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	27×27×128	Weights 3×3×32×128 Bias 1×1×128
24	<b>fire4-relu_expand3x3</b> ReLU	ReLU	27×27×128	-
25	<b>fire4-relu_expand1x1</b> ReLU	ReLU	27×27×128	-
26	<b>fire4-concat</b> Depth concatenation of 2 inputs	Depth concatenation	27×27×256	-
27	<b>fire5-squeeze1x1</b> 32 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	27×27×32	Weights 1×1×256×32 Bias 1×1×32
28	<b>fire5-relu_squeeze1x1</b> ReLU	ReLU	27×27×32	-

	Name	Type	Activations	Learnables
29	fire5-expand1x1 128 1x1x32 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	27x27x128	Weights 1x1x32x128 Bias 1x1x128
30	fire5-expand3x3 128 3x3x32 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	27x27x128	Weights 3x3x32x128 Bias 1x1x128
31	fire5-relu_expand3x3 ReLU	ReLU	27x27x128	-
32	fire5-relu_expand1x1 ReLU	ReLU	27x27x128	-
33	fire5-concat Depth concatenation of 2 inputs	Depth concatenation	27x27x256	-
34	pool5 3x3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	13x13x256	-
35	fire6-squeeze1x1 48 1x1x256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x48	Weights 1x1x256x48 Bias 1x1x48
36	fire6-relu_squeeze1x1 ReLU	ReLU	13x13x48	-
37	fire6-expand1x1 192 1x1x48 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x192	Weights 1x1x48x192 Bias 1x1x192
38	fire6-expand3x3 192 3x3x48 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	13x13x192	Weights 3x3x48x192 Bias 1x1x192
39	fire6-relu_expand3x3 ReLU	ReLU	13x13x192	-
40	fire6-relu_expand1x1 ReLU	ReLU	13x13x192	-
41	fire6-concat Depth concatenation of 2 inputs	Depth concatenation	13x13x384	-
42	fire7-squeeze1x1 48 1x1x384 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x48	Weights 1x1x384x48 Bias 1x1x48
43	fire7-relu_squeeze1x1 ReLU	ReLU	13x13x48	-
44	fire7-expand3x3 192 3x3x48 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	13x13x192	Weights 3x3x48x192 Bias 1x1x192
45	fire7-relu_expand3x3 ReLU	ReLU	13x13x192	-
46	fire7-expand1x1 192 1x1x48 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x192	Weights 1x1x48x192 Bias 1x1x192
47	fire7-relu_expand1x1 ReLU	ReLU	13x13x192	-
48	fire7-concat Depth concatenation of 2 inputs	Depth concatenation	13x13x384	-
49	fire8-squeeze1x1 64 1x1x384 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x64	Weights 1x1x384x64 Bias 1x1x64
50	fire8-relu_squeeze1x1 ReLU	ReLU	13x13x64	-
51	fire8-expand3x3 256 3x3x64 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	13x13x256	Weights 3x3x64x256 Bias 1x1x256
52	fire8-relu_expand3x3 ReLU	ReLU	13x13x256	-
53	fire8-expand1x1 256 1x1x64 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x256	Weights 1x1x64x256 Bias 1x1x256
54	fire8-relu_expand1x1 ReLU	ReLU	13x13x256	-
55	fire8-concat Depth concatenation of 2 inputs	Depth concatenation	13x13x512	-
56	fire9-squeeze1x1 64 1x1x512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13x13x64	Weights 1x1x512x64 Bias 1x1x64
57	fire9-relu_squeeze1x1 ReLU	ReLU	13x13x64	-

58	<b>fire9-expand3x3</b> 256 3×3×64 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	13×13×256	Weights 3×3×64×256 Bias 1×1×256
59	<b>fire9-expand1x1</b> 256 1×1×64 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13×13×256	Weights 1×1×64×256 Bias 1×1×256
60	<b>fire9-relu_expand3x3</b> ReLU	ReLU	13×13×256	-
61	<b>fire9-relu_expand1x1</b> ReLU	ReLU	13×13×256	-
62	<b>fire9-concat</b> Depth concatenation of 2 inputs	Depth concatenation	13×13×512	-
63	<b>drop9</b> 50% dropout	Dropout	13×13×512	-
64	<b>conv10</b> 2 1×1 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	13×13×2	Weights 1×1×512×2 Bias 1×1×2
65	<b>relu_conv10</b> ReLU	ReLU	13×13×2	-
66	<b>pool10</b> Global average pooling	Global Average Po...	1×1×2	-
67	<b>prob</b> softmax	Softmax	1×1×2	-
68	<b>ClassificationLayer_predictions</b> crossentropyex	Classification Output	1×1×2	-

## EK 3. DARKNET AĞ YAPISI

	Name	Type	Activations	Learnables
1	<b>input</b> 224x224x3 images with 'zero-center' normalization	Image Input	224x224x3	-
2	<b>conv1</b> 32 3x3x3 convolutions with stride [1 1] and padding 'same'	Convolution	224x224x32	Weights 3x3x3x32 Bias 1x1x32
3	<b>batchnorm1</b> Batch normalization with 32 channels	Batch Normalization	224x224x32	Offset 1x1x32 Scale 1x1x32
4	<b>leakyrelu1</b> Leaky ReLU with scale 0.1	Leaky ReLU	224x224x32	-
5	<b>conv2</b> 64 3x3x32 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	112x112x64	Weights 3x3x32x64 Bias 1x1x64
6	<b>batchnorm2</b> Batch normalization with 64 channels	Batch Normalization	112x112x64	Offset 1x1x64 Scale 1x1x64
7	<b>leakyrelu2</b> Leaky ReLU with scale 0.1	Leaky ReLU	112x112x64	-
8	<b>conv3</b> 32 1x1x64 convolutions with stride [1 1] and padding 'same'	Convolution	112x112x32	Weights 1x1x64x32 Bias 1x1x32
9	<b>batchnorm3</b> Batch normalization with 32 channels	Batch Normalization	112x112x32	Offset 1x1x32 Scale 1x1x32
10	<b>leakyrelu3</b> Leaky ReLU with scale 0.1	Leaky ReLU	112x112x32	-
11	<b>conv4</b> 64 3x3x32 convolutions with stride [1 1] and padding 'same'	Convolution	112x112x64	Weights 3x3x32x64 Bias 1x1x64
12	<b>batchnorm4</b> Batch normalization with 64 channels	Batch Normalization	112x112x64	Offset 1x1x64 Scale 1x1x64
13	<b>leakyrelu4</b> Leaky ReLU with scale 0.1	Leaky ReLU	112x112x64	-
14	<b>res1</b> Element-wise addition of 2 inputs	Addition	112x112x64	-
15	<b>conv5</b> 128 3x3x64 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	56x56x128	Weights 3x3x64x128 Bias 1x1x128
16	<b>batchnorm5</b> Batch normalization with 128 channels	Batch Normalization	56x56x128	Offset 1x1x128 Scale 1x1x128
17	<b>leakyrelu5</b> Leaky ReLU with scale 0.1	Leaky ReLU	56x56x128	-
18	<b>conv6</b> 64 1x1x128 convolutions with stride [1 1] and padding 'same'	Convolution	56x56x64	Weights 1x1x128x64 Bias 1x1x64
19	<b>batchnorm6</b> Batch normalization with 64 channels	Batch Normalization	56x56x64	Offset 1x1x64 Scale 1x1x64
20	<b>leakyrelu6</b> Leaky ReLU with scale 0.1	Leaky ReLU	56x56x64	-
21	<b>conv7</b> 128 3x3x64 convolutions with stride [1 1] and padding 'same'	Convolution	56x56x128	Weights 3x3x64x128 Bias 1x1x128
22	<b>batchnorm7</b> Batch normalization with 128 channels	Batch Normalization	56x56x128	Offset 1x1x128 Scale 1x1x128
23	<b>leakyrelu7</b> Leaky ReLU with scale 0.1	Leaky ReLU	56x56x128	-
24	<b>res2</b> Element-wise addition of 2 inputs	Addition	56x56x128	-
25	<b>conv8</b> 64 1x1x128 convolutions with stride [1 1] and padding 'same'	Convolution	56x56x64	Weights 1x1x128x64 Bias 1x1x64

	Name	Type	Activations	Learnables
26	<b>batchnorm8</b> Batch normalization with 64 channels	Batch Normalization	56×56×64	Offset 1×1×64 Scale 1×1×64
27	<b>leakyrelu8</b> Leaky ReLU with scale 0.1	Leaky ReLU	56×56×64	-
28	<b>conv9</b> 128 3×3×64 convolutions with stride [1 1] and padding 'same'	Convolution	56×56×128	Weights 3×3×64×128 Bias 1×1×128
29	<b>batchnorm9</b> Batch normalization with 128 channels	Batch Normalization	56×56×128	Offset 1×1×128 Scale 1×1×128
30	<b>leakyrelu9</b> Leaky ReLU with scale 0.1	Leaky ReLU	56×56×128	-
31	<b>res3</b> Element-wise addition of 2 inputs	Addition	56×56×128	-
32	<b>conv10</b> 256 3×3×128 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
33	<b>batchnorm10</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
34	<b>leakyrelu10</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
35	<b>conv11</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
36	<b>batchnorm11</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
37	<b>leakyrelu11</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
38	<b>conv12</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
39	<b>batchnorm12</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
40	<b>leakyrelu12</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
41	<b>res4</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
42	<b>conv13</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
43	<b>batchnorm13</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
44	<b>leakyrelu13</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
45	<b>conv14</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
46	<b>batchnorm14</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
47	<b>leakyrelu14</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
48	<b>res5</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
49	<b>conv15</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
50	<b>batchnorm15</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128

	Name	Type	Activations	Learnables
51	<b>leakyrelu15</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
52	<b>conv16</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
53	<b>batchnorm16</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
54	<b>leakyrelu16</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
55	<b>res6</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
56	<b>conv17</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
57	<b>batchnorm17</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
58	<b>leakyrelu17</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
59	<b>conv18</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
60	<b>batchnorm18</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
61	<b>leakyrelu18</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
62	<b>res7</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
63	<b>conv19</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
64	<b>batchnorm19</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
65	<b>leakyrelu19</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
66	<b>conv20</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
67	<b>batchnorm20</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
68	<b>leakyrelu20</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
69	<b>res8</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
70	<b>conv21</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
71	<b>batchnorm21</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
72	<b>leakyrelu21</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
73	<b>conv22</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
74	<b>batchnorm22</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
75	<b>leakyrelu22</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-



	Name	Type	Activations	Learnables
76	<b>res9</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
77	<b>conv23</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
78	<b>batchnorm23</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
79	<b>leakyrelu23</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
80	<b>conv24</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
81	<b>batchnorm24</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
82	<b>leakyrelu24</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
83	<b>res10</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
84	<b>conv25</b> 128 1×1×256 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
85	<b>batchnorm25</b> Batch normalization with 128 channels	Batch Normalization	28×28×128	Offset 1×1×128 Scale 1×1×128
86	<b>leakyrelu25</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×128	-
87	<b>conv26</b> 256 3×3×128 convolutions with stride [1 1] and padding 'same'	Convolution	28×28×256	Weights 3×3×128×256 Bias 1×1×256
88	<b>batchnorm26</b> Batch normalization with 256 channels	Batch Normalization	28×28×256	Offset 1×1×256 Scale 1×1×256
89	<b>leakyrelu26</b> Leaky ReLU with scale 0.1	Leaky ReLU	28×28×256	-
90	<b>res11</b> Element-wise addition of 2 inputs	Addition	28×28×256	-
91	<b>conv27</b> 512 3×3×256 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
92	<b>batchnorm27</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
93	<b>leakyrelu27</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
94	<b>conv28</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
95	<b>batchnorm28</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
96	<b>leakyrelu28</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
97	<b>conv29</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
98	<b>batchnorm29</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
99	<b>leakyrelu29</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
100	<b>res12</b> Element-wise addition of 2 inputs	Addition	14×14×512	-

	Name	Type	Activations	Learnables
101	<b>conv30</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
102	<b>batchnorm30</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
103	<b>leakyrelu30</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
104	<b>conv31</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
105	<b>batchnorm31</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
106	<b>leakyrelu31</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
107	<b>res13</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
108	<b>conv32</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
109	<b>batchnorm32</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
110	<b>leakyrelu32</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
111	<b>conv33</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
112	<b>batchnorm33</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
113	<b>leakyrelu33</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
114	<b>res14</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
115	<b>conv34</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
116	<b>batchnorm34</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
117	<b>leakyrelu34</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
118	<b>conv35</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
119	<b>batchnorm35</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
120	<b>leakyrelu35</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
121	<b>res15</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
122	<b>conv36</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
123	<b>batchnorm36</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
124	<b>leakyrelu36</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
125	<b>conv37</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512

	Name	Type	Activations	Learnables
126	<b>batchnorm37</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
127	<b>leakyrelu37</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
128	<b>res16</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
129	<b>conv38</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
130	<b>batchnorm38</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
131	<b>leakyrelu38</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
132	<b>conv39</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
133	<b>batchnorm39</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
134	<b>leakyrelu39</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
135	<b>res17</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
136	<b>conv40</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
137	<b>batchnorm40</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
138	<b>leakyrelu40</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
139	<b>conv41</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
140	<b>batchnorm41</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
141	<b>leakyrelu41</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
142	<b>res18</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
143	<b>conv42</b> 256 1×1×512 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×256	Weights 1×1×512×256 Bias 1×1×256
144	<b>batchnorm42</b> Batch normalization with 256 channels	Batch Normalization	14×14×256	Offset 1×1×256 Scale 1×1×256
145	<b>leakyrelu42</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×256	-
146	<b>conv43</b> 512 3×3×256 convolutions with stride [1 1] and padding 'same'	Convolution	14×14×512	Weights 3×3×256×512 Bias 1×1×512
147	<b>batchnorm43</b> Batch normalization with 512 channels	Batch Normalization	14×14×512	Offset 1×1×512 Scale 1×1×512
148	<b>leakyrelu43</b> Leaky ReLU with scale 0.1	Leaky ReLU	14×14×512	-
149	<b>res19</b> Element-wise addition of 2 inputs	Addition	14×14×512	-
150	<b>conv44</b> 1024 3×3×512 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024

	Name	Type	Activations	Learnables
150	<b>conv44</b> 1024 3×3×512 convolutions with stride [2 2] and padding [1 0 1 0]	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024
151	<b>batchnorm44</b> Batch normalization with 1024 channels	Batch Normalization	7×7×1024	Offset 1×1×1024 Scale 1×1×1024
152	<b>leakyrelu44</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×1024	-
153	<b>conv45</b> 512 1×1×1024 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×512	Weigh... 1×1×1024×5... Bias 1×1×512
154	<b>batchnorm45</b> Batch normalization with 512 channels	Batch Normalization	7×7×512	Offset 1×1×512 Scale 1×1×512
155	<b>leakyrelu45</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×512	-
156	<b>conv46</b> 1024 3×3×512 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024
157	<b>batchnorm46</b> Batch normalization with 1024 channels	Batch Normalization	7×7×1024	Offset 1×1×1024 Scale 1×1×1024
158	<b>leakyrelu46</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×1024	-
159	<b>res20</b> Element-wise addition of 2 inputs	Addition	7×7×1024	-
160	<b>conv47</b> 512 1×1×1024 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×512	Weigh... 1×1×1024×5... Bias 1×1×512
161	<b>batchnorm47</b> Batch normalization with 512 channels	Batch Normalization	7×7×512	Offset 1×1×512 Scale 1×1×512
162	<b>leakyrelu47</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×512	-
163	<b>conv48</b> 1024 3×3×512 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024
164	<b>batchnorm48</b> Batch normalization with 1024 channels	Batch Normalization	7×7×1024	Offset 1×1×1024 Scale 1×1×1024
165	<b>leakyrelu48</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×1024	-
166	<b>res21</b> Element-wise addition of 2 inputs	Addition	7×7×1024	-
167	<b>conv49</b> 512 1×1×1024 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×512	Weigh... 1×1×1024×5... Bias 1×1×512
168	<b>batchnorm49</b> Batch normalization with 512 channels	Batch Normalization	7×7×512	Offset 1×1×512 Scale 1×1×512
169	<b>leakyrelu49</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×512	-
170	<b>conv50</b> 1024 3×3×512 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024
171	<b>batchnorm50</b> Batch normalization with 1024 channels	Batch Normalization	7×7×1024	Offset 1×1×1024 Scale 1×1×1024
172	<b>leakyrelu50</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×1024	-
173	<b>res22</b> Element-wise addition of 2 inputs	Addition	7×7×1024	-
174	<b>conv51</b> 512 1×1×1024 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×512	Weigh... 1×1×1024×5... Bias 1×1×512

175	<b>batchnorm51</b> Batch normalization with 512 channels	Batch Normalization	7×7×512	Offset 1×1×512 Scale 1×1×512
176	<b>leakyrelu51</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×512	-
177	<b>conv52</b> 1024 3×3×512 convolutions with stride [1 1] and padding 'same'	Convolution	7×7×1024	Weigh... 3×3×512×10... Bias 1×1×1024
178	<b>batchnorm52</b> Batch normalization with 1024 channels	Batch Normalization	7×7×1024	Offset 1×1×1024 Scale 1×1×1024
179	<b>leakyrelu52</b> Leaky ReLU with scale 0.1	Leaky ReLU	7×7×1024	-
180	<b>res23</b> Element-wise addition of 2 inputs	Addition	7×7×1024	-
181	<b>avg1</b> Global average pooling	Global Average Po...	1×1×1024	-
182	<b>conv53</b> 2 1×1 convolutions with stride [1 1] and padding 'same'	Convolution	1×1×2	Weights 1×1×1024×2 Bias 1×1×2
183	<b>softmax</b> softmax	Softmax	1×1×2	-
184	<b>output</b> crossentropyex	Classification Output	1×1×2	-