



**DEPREME DAYANIKLI MİMARİ TASARIM AŞAMASINDA DERİN  
ÖĞRENME VE GÖRÜNTÜ SINIFLAMA YÖNTEMİ İLE BURULMA  
DÜZENSİZLİĞİ TESPİTİ**

**KAAN BİNGÖL**

**ŞUBAT 2020**

ÇANKAYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MİMARLIK ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

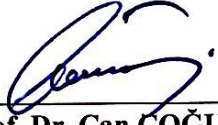
DEPREME DAYANIKLI MİMARİ TASARIM AŞAMASINDA DERİN  
ÖĞRENME VE GÖRÜNTÜ SINIFLAMA YÖNTEMİ İLE BURULMA  
DÜZENSİZLİĞİ TESPİTİ

KAAN BİNGÖL

ŞUBAT 2020

Tez Başlığı : Depreme Dayanıklı Mimari Tasarım Aşamasında Derin  
Öğrenme ve Görüntü Sınıflama Yöntemi ile Burulma Düzensizliği Tespiti  
Tezi Hazırlayan: KAAAN BİNGÖL


Fen Bilimleri Enstitüsü Onayı

  
Prof. Dr. Can ÇOĞUN  
Enstitü Müdürü

Bu tezin yüksek lisans derecesi elde etmek için gerekli koşulları sağladığımı onaylarım.

  
Doç. Dr. Gülsu ULUKAVAK HARPUTLUGİL  
Mimarlık  
ABD Başkanı

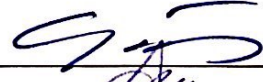

Bu tez, tarafımdan incelenmiş olup Yüksek Lisans Tezi olarak uygun bulunmuştur.

  
Doç. Dr. Aslı ER AKAN  
Tez Danışmanı

Tez Jüri Tarihi: 05.02.2020

Tez Jüri Üyeleri

Prof. Dr. Gülser ÇELEBİ (Çankaya Univ.)  
Prof. Dr. Ali Ihsan ÜNAY (Gazi Univ.)  
Doç. Dr. Aslı ER AKAN (Çankaya Univ.)

**ÇANKAYA ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE**

Bu belgedeki tüm bilgilerin akademik kurallara ve etik davranışlara uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bu kurallar ve davranışların gerektirdiği gibi, bu işe orijinal olmayan tüm materyal ve sonuçları tamamen gösterdiğimi ve referans verdiğimi beyan ederim.

Adı, Soyadı : Kaan Bingöl

İmza : 

Tarih : 25.03.2020

## ÖZET

# DEPREME DAYANIKLI MİMARİ TASARIM AŞAMASINDA DERİN ÖĞRENME VE GÖRÜNTÜ SINIFLAMA YÖNTEMİ İLE BURULMA DÜZENSİZLİĞİ TESPİTİ

BİNGÖL, Kaan

Fen Bilimleri Enstitüsü, Mimarlık Bölümü

Tez Danışmanı: Doç. Dr. Aslı ER AKAN

Şubat 2020, 79 sayfa

Mimari tasarım süreci, ana tasarım kararlarının alınmasından detaylandırma aşamasına kadar, farklı birçok konuda uzmanlaşmış kişilerin iş birliği ile gerçekleşse de, ana kararların alınması, plan organizasyonu, kütle kurgusu vb. temel kararlar mimar tarafından alınmaktadır. Bilgisayar Destekli Tasarım (CAD- Computer Aided Design ) ve Yapı Bilgi Modelleme (BIM- Building Information Modeling ) programları ise genellikle, tasarımın ana kararları alındıktan sonra etkili olmaktadır. Bu nedenle, süreçte alınan ana kararların taşıyıcı sistem hesabı sırasında değiştirilmesinin gerekmesi ise sıkça rastlanan bir durum haline gelmektedir. Bunun oluşmaması için mimari tasarımın erken evrelerinde deprem mimarlığı bilinciyle taşıyıcı sistem kurgusunun bir tasarım girdisi olarak sürece katılması gerekir; çünkü mimari tasarım aşamasında taşıyıcı sistem kurgusunun iyi düşünülmemesi, uygulama projesi aşamasında beklenmedik revizyonlarla karşılaşılmasına ve dolayısıyla hem süreç hem de maliyet olarak ciddi kayıplara neden olmaktadır.

Bu çalışmanın amacı, söz konusu probleme çözüm oluşturacak şekilde, derin öğrenme ve görüntü işleme yöntemleri kullanarak, tasarımın erken evrelerinde, mimarlara taşıyıcı sistem kararlarının deprem yönetmeliğine uygunluğu hakkında genel bilgiler verebilecek bir Düzensizlik Kontrol Asistanı (DK-Asistanı)

oluřturulmasıdır. Bylelikle, tasarımıın erken ařamasında doęru kararlar alınması saęlanacak, uygulama projesi ařamasında gerekleřebilecek beklenmedik revizyonlar engellenebilecektir.

**Anahtar Kelimeler:** Yapay Zeka, Derin ğrenme, Deprem Ynetmelięi, ImageAI, Grnt Sınıflandırma, Grnt İřleme, Python



## **ABSTRACT**

# **TORSIONAL IRREGULARITY DETECTION WITH DEEP LEARNING and IMAGE CLASSIFICATION METHOD in EARTHQUAKE RESISTANT ARCHITECTURAL DESIGN PROCESS**

BİNGÖL, Kaan

M.S.c., Department of Architecture

Supervisor: Doç. Dr. Aslı ER AKAN

February 2020, 79 pages

Although the architectural design process is carried out with the collaboration of experts who are experienced in many different areas from the main preferences to the detailing stage, the major decisions such as plan organization, mass design etc. are taken by the architect. Computer Aided Design (CAD) programs are generally effective after the major decisions of the design are taken. For this reason, it is common for the main decisions, taken during the design process, to be changed during the analysis of the structural system.

In order to prevent this, in the early stages of architectural design, earthquake system awareness and structural system design should be included as an design input; as, the failure of the structural system which did not considered well in the architectural design phase leads to unexpected revisions in the implementation project phase and thus leads to serious losses in both time and cost.

The aim of this study is to create an Irregularity Control Assistant (IC Assistant) that can provide architects general information about the appropriateness of structural system decisions to earthquake regulations in the early stages of design process by using the deep learning and image processing methods. In this way, correct decisions

will be made in the early stages of the design and unexpected revisions that may occur during the implementation project phase will be prevented.

**Keywords:** Artificial Intelligence, Deep Learning, Earthquake Code, ImageAI, Image Classification, Image Processing, Python





## TEŐEKKÜR

Bütün bu alıőmaları gerekleőtirmem için bana inanan, yapay zekâ programlama ve mimari tasarımda uygulama alanlarını araőtırarak örnek bir uygulama geliőtirme fırsatı veren, deęerli yardım ve katkıları ile beni yönlendirerek bu tezin yazılmasında benim kadar emeęi geen Danıőman Hocam Sayın Do. Dr. Aslı ER AKAN ‘a,

Yapay zeka ve görüntü işleme üzerinde deęerli yöntem önerileri için Sayın Prof. Dr. Veysi İşler’e,

Lisansüstü öğrenime başlarken, yapı yazılımları konusunda tereddütlerimi ortadan kaldıran ve yapay zekâ programlama konusunda yönlendiren ve cesaretlendiren Sayın Prof. Dr. Yusuf Arayıcı’ya,

Lisans dönemimde mimarlık mesleęini bana sevdiren ve öğretileri ile vizyon katan Sayın Prof. Dr. Haluk Pamir’e katkıları ve verdikleri motivasyonlar için teşekkür ederim.

Kaan BİNGÖL

## İÇİNDEKİLER

|  |      |
|--|------|
| ÖZET.....  | iv   |
| ABSTRACT .....   | vi   |
| TEŞEKKÜR.....  | viii |
| İÇİNDEKİLER .....  | ix   |
| ŞEKİLLER LİSTESİ .....   | xii  |
| TABLolar LİSTESİ.....  | xiv  |
| GRAFİKLER LİSTESİ.....   | xv   |
| BİRİNCİ BÖLÜM .....  | 1    |
| 1. GİRİŞ .....   | 1    |
| 1.1. Problem Tanımı.....   | 1    |
| 1.2. Araştırmanın Amacı ve Önemi .....                                   | 4    |
| 1.3. Araştırmanın Yöntemi.....   | 4    |
| İKİNCİ BÖLÜM.....  | 6    |
| 2. LİTERATÜR BİLGİSİ .....   | 6    |
| 2.1. Yapay Zekâ Nedir? .....   | 6    |
| 2.1.1. İnsan Gibi Davranan Makineler .....                               | 7    |
| 2.1.2. Rasyonel Düşünen Makineler (Düşünce Yasaları Yaklaşımı).....      | 8    |
| 2.1.3. İnsan Gibi Düşünen Makineler (Bilişsel Modelleme Yaklaşımı) ..... | 8    |
| 2.1.4. Rasyonel Davranan Makineler (Rasyonel Etmen Yaklaşımı) .....      | 9    |
| 2.2. Makine Öğrenimi .....   | 9    |
| 2.2.1. Bulanık Mantık.....   | 11   |
| 2.2.2. Yapay Sinir Ağları (Artificial Neural Network) .....              | 12   |
| 2.2.3. Derin Yapay Sinir Ağları ve Derin Öğrenme .....                   | 14   |
| 2.2.4. Derin Öğrenme Mimarileri .....                                    | 15   |
| 2.2.5. Konveksiyonel Sinir Ağı Sınıfı ve Görüntü İşleme .....            | 16   |

|  |    |
|--|----|
| ÜÇÜNCÜ BÖLÜM .....   | 17 |
| 3. DEPREME DAYANIKLI MİMARİ TASARIMDA DERİN ÖĞRENME VE GÖRÜNTÜ SINIFLANDIRMA UYGULAMALARININ KULLANIMI ..... | 17 |
| 3.1. Deprem'in Yapılar Üzerindeki Etkisi.....  | 24 |
| 3.2. Deprem ve Taşıyıcı Sistem Tasarım İlkeleri.....   | 26 |
| 3.3. Düzensiz Binaların Tanımı .....   | 27 |
| 3.3.1. Planda Düzensizlik Durumları .....  | 27 |
| 3.3.2. Düşeyde Düzensizlik Durumları .....   | 30 |
| 3.4. Düzensiz Bina Tasarımının Deprem Davranışına Etkisi .....   | 31 |
| 3.4.1. Rijitlik Merkezi .....  | 32 |
| DÖRDÜNCÜ BÖLÜM.....  | 35 |
| 4. KULLANILAN MATERYALLER.....   | 35 |
| 4.1. Düzensizlik Kontrol Asistanının Kurgusu .....   | 35 |
| 4.1.1. Kullanılan Materyaller .....  | 36 |
| 4.2. Veri Setleri .....  | 38 |
| 4.2.1. Veri Setlerinin Hiyerarşisi.....  | 39 |
| 4.2.2. Görüntü Çoğaltma.....   | 43 |
| 4.2.3. Modeller .....  | 45 |
| 4.2.4. Model Eğitimi .....   | 47 |
| 4.2.5. DK-Asistanı Uygulamasının Kullanıcı Arabirimi .....   | 49 |
| BEŞİNCİ BÖLÜM.....   | 50 |
| 5. DÜZENSİZLİK KONTROL ASİSTANININ UYGULANMASI VE DOĞRULANMASI .....   | 50 |
| 5.1. DK-Asistanı ve Prota-Structure ile Test Edilen Şemalar .....  | 50 |
| 5.1.1. 5x4 Dikdörtgen Düzensiz Plan Şeması .....   | 53 |
| 5.1.2. 5x4 Dikdörtgen Düzenli Plan Şeması .....  | 55 |
| 5.1.3. 10x4 Dikdörtgen Düzensiz Plan Şeması .....  | 57 |
| 5.1.4. 10x4 Dikdörtgen Düzenli Plan Şeması .....   | 59 |
| 5.1.5. 9x6 Elips Düzenli Plan Şeması .....   | 61 |
| 5.1.6. 9x6 Elips Düzensiz Plan Şeması .....  | 63 |

|  |    |
|--|----|
| 5.1.7. 3x4 Kare Düzensiz Plan Şeması ..... | 65 |
| 5.1.8. 7x4 Kare Düzensiz Plan Şeması ..... | 67 |
| Test Sonuçları.....                        | 69 |
| ALTINCI BÖLÜM .....                        | 72 |
| SONUÇ .....                                | 72 |
| KAYNAKÇA .....                             | 74 |
| EKLER.....                                 | 79 |
| EK-1 ÖZ GEÇMİŞ.....                        | 79 |



## ŞEKİLLER LİSTESİ

|   |    |
|---|----|
| Şekil 1: Yapay Zeka Çalışma Alanları (Mills, 2016).....   | 3  |
| Şekil 2: DK-Asistanının Çalışma Diyagramı.....  | 5  |
| Şekil 3 Yapay Zekanın Çalışma Alanları, Mattab, M. (2019). ....                                 | 7  |
| Şekil 4 : Makine Öğrenim Türleri.....   | 11 |
| Şekil 5: Biyolojik Sinir Ağı (Yılmaz A. , 2018) .....   | 12 |
| Şekil 6: Yapay Sinir Hücresi Şeması (Yılmaz A. , 2018).....                                     | 13 |
| Şekil 7: Tek Katmanlı Bir Yapay Sinir Ağının Temel Yapısı .....                                 | 13 |
| Şekil 8 Derin Yapay Sinir Ağı (Waldrop, 2020).....  | 14 |
| Şekil 9: Autocad Üzerinde Çalışan A1 Düzensizlik Uygulaması (İdemen, 2003) ....                 | 17 |
| Şekil 10: Makine Öğrenimi ile Oluşturulmuş Kolon Başlıkları (Cudzik & Radziszewski, 2018). .... | 19 |
| Şekil 11: Sürü Zekası ile Oluşturulmuş Tasarım (Cudzik & Radziszewski, 2018)...                 | 20 |
| Şekil 12: GAN Kullanımı (Huang & Zheng, 2018).....  | 20 |
| Şekil 13: Eskiz Plan ve Kesit Çizimi (Uzun & Çorakoğlu, 2019).....                              | 21 |
| Şekil 14: Sydney Opera Binası Plan ve Kesitleri (Jennifer, ve diğerleri, 2019).....             | 22 |
| Şekil 15: Kültürel Öğelerin Veri Seti Örneği (Llamas ve d., 2017) .....                         | 23 |
| Şekil 16. Burulma Düzensizliği (Torsional Irregularity) (TBDY, 2018).....                       | 28 |
| Şekil 17: Döşeme Düzensizliği (Floor Discontinuity) (TBDY, 2018). ....                          | 29 |
| Şekil 18 : Planda Çıkıntılar Bulunması (Projections in Plan) (TBDY, 2018) .....                 | 29 |
| Şekil 19: Düşeyde Düzensizlik Durumları.....  | 30 |
| Şekil 20 Taşıyıcı Sistemin Düşey Elemanlarının Süreksizliği.....                                | 31 |
| Şekil 21: Kütle ve Ağırlık Merkezi Şeması .....   | 32 |
| Şekil 22: Dış Merkezlik ve Deprem Kuvveti Şeması .....  | 33 |
| Şekil 23: Düzensiz Plan ve Düzensiz Şeması .....  | 38 |
| Şekil 24: Veri Setinin Dosya Hiyerarşisi .....  | 39 |
| Şekil 25: Düzenli Veri Seti Sınıfı Örnekleme .....  | 41 |
| Şekil 26: Düzensiz Veri Seti Sınıfı Örnekleme .....   | 42 |
| Şekil 27: Görüntü Çoğullama Akış Diyagramı.....   | 43 |

|   |    |
|---|----|
| Şekil 28: İmaj Çoğullama İşlemi.....  | 44 |
| Şekil 29: M1 ve M2 Veri Setinin Örnekleme.....  | 45 |
| Şekil 30: M3 ve M4 Veri Setinin Örnekleme.....  | 45 |
| Şekil 31: M5 Veri Setinin Örnekleme.....  | 46 |
| Şekil 32: M6 Veri Setinin Örnekleme.....  | 46 |
| Şekil 33: Eğitim Öncesi Örnek Dosya Hiyerarşisi.....  | 47 |
| Şekil 34: DK-Asistanı Arayüzü.....  | 49 |
| Şekil 35: Test Planları.....  | 51 |
| Şekil 36: 5x4 Dikdörtgen Düzensiz Planın Prota-Structure Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....      | 54 |
| Şekil 37: 5x4 Dikdörtgen Düzenli Planın Prota-Structure'a Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....     | 56 |
| Şekil 38: 10x4 Dikdörtgen Düzensiz Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....   | 58 |
| Şekil 39: 10x4 Dikdörtgen Düzensiz Planın Prota-Structure'a Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....   | 60 |
| Şekil 40: 9x6 Elips Düzenli Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....          | 62 |
| Şekil 41: 9x6 Elips Düzensiz Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....         | 64 |
| Şekil 42: 3x4 Kare Düzensiz Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı.....          | 66 |
| Şekil 43: 7x4 Kare Düzensiz Planın Prota-Structure Yazılımına Göre Rijitlik ve Ağırlık Merkezlerinin Farkı..... | 68 |

## TABLolar LİSTESİ

|   |    |
|---|----|
| Tablo 1: Veri Setlerinden Örneklem .....  | 40 |
| Tablo 2: Model Eğitim Parametreleri .....   | 48 |
| Tablo 3: 5x4 Dikdörtgen Düzensiz Plan Şeması ve DK-Asistanının Sonuçları .....                            | 53 |
| Tablo 4: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları ..... | 54 |
| Tablo 5: 5x4 Dikdörtgen Düzenli Plan Şeması ve DK-Asistanının Sonuçları .....                             | 55 |
| Tablo 6: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları ..... | 56 |
| Tablo 7: 10x4 Dikdörtgen Düzensiz Plan Şeması ve DK-Asistanının Sonuçları .....                           | 57 |
| Tablo 8: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları ..... | 58 |
| Tablo 9: 10x4 Dikdörtgen Düzenli Plan Şeması ve DK-Asistanının Sonuçları .....                            | 59 |
| Tablo 10: Prota-Structure Koordinatları ve Dış Merkezlik Hesaplaması .....                                | 60 |
| Tablo 11: 9x6 Elips Düzenli Plan Şeması ve DK-Asistanının Sonuçları .....                                 | 61 |
| Tablo 12: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması.....                                 | 62 |
| Tablo 13: 9x6 Elips Düzensiz Plan Şeması ve DK-Asistanının Sonuçları .....                                | 63 |
| Tablo 14: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması.....                                 | 64 |
| Tablo 15: Kare Düzensiz Plan Şeması ve DK-Asistanı Sonuçları.....   | 65 |
| Tablo 16: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması.....                                 | 66 |
| Tablo 17: 7x4 Kare Düzensiz Plan Şeması ve DK-Asistanı Sonuçları.....                                     | 67 |
| Tablo 18: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması.....                                 | 68 |
| Tablo 19: DK-Asistanı ve Prota-Structure Sonuçlarının Karşılaştırılması .....                             | 70 |

## GRAFİKLER LİSTESİ

|   |    |
|---|----|
| Grafik 1: Ham ve Artırılmış Setin Farkı ..... | 44 |
| Grafik 2: Veri Setleri Sayısı.....            | 46 |





# BİRİNCİ BÖLÜM

## GİRİŞ

### 1.1. Problem Tanımı

Günümüzde her alanda olduğu gibi mimarlar tarafından kullanılan dijital araçlar da sürekli olarak gelişmekte ve tasarım sürecinin vazgeçilmez birer parçası haline gelmektedir. Artan ihtiyaçlar doğrultusunda, mimarlık alanında kullanılan ilk programlar 2B çizim programları iken zamanla 3B tasarım programları, enerji ve akustik hesaplama programları, maliyet tahmini, strüktürel analiz ve çevresel benzetim programları gibi ürünlerle bu programlar çeşitlenmiş ve yetenekleri artmıştır. Son olarak, proje tasarımını ve yönetimini kolaylaştırmayı, yapı tasarımı aşamasına katılan farklı disiplinlerdeki kişilerin –mimarlar, inşaat mühendisleri, elektrik mühendisleri, mekanik mühendisleri vb. iletişim problemlerini tek bir çatı altında toplayarak ortadan kaldırmayı hedefleyen BIM (Bina Bilgi Yönetimi) sistemleri ortaya çıkmıştır. Süreçte kullanılan araçların yeteneklerinin artması, dolaylı olarak mimari tasarım aşamalarının da kısmen dönüşmesine sebep olmuş olsa da, temel olarak tasarım sürecindeki ana kararlar tasarımcı mimara ait olmaya devam etmektedir. Bunun ana nedeni, bahsedilen programların tamamının tasarım sürecinin ana kararları alındıktan sonra devreye girmesidir. Süreçte mimar halen ana kararları verirken kendi bilgi, tecrübe ve yetenekleri doğrultusunda karar vermekte, karar veremediği durumlarda ise uzmanlık sahibi birine danışmaktadır.

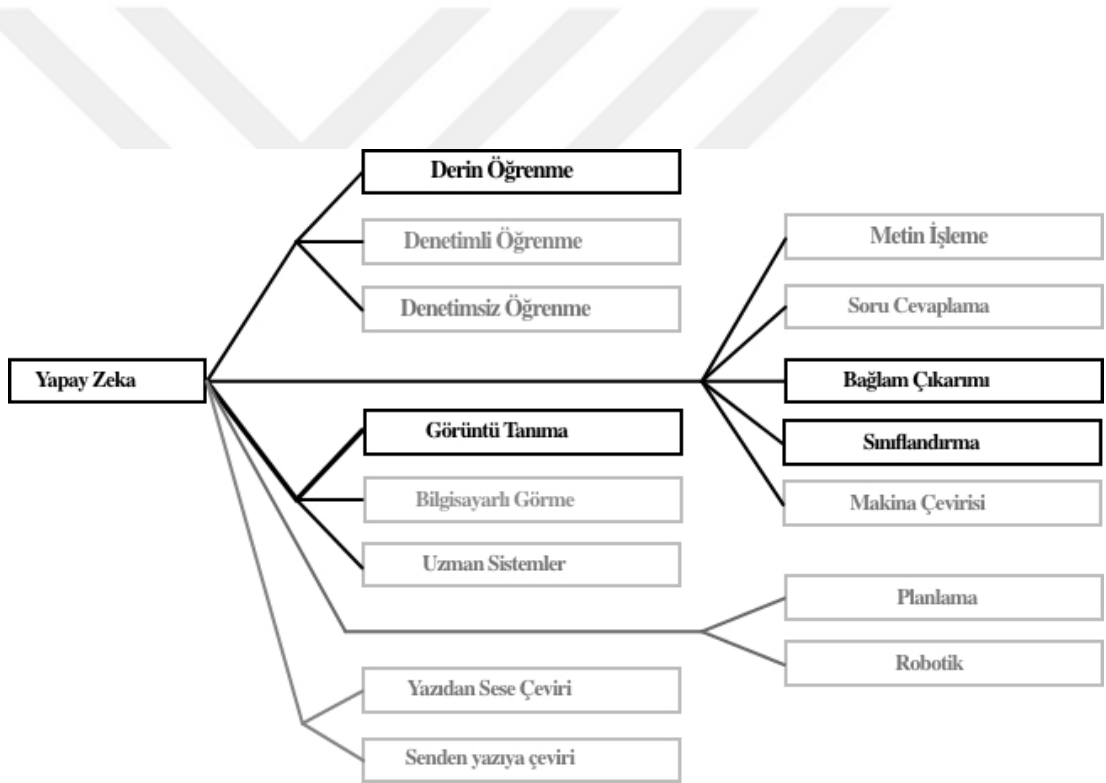
Bilgisayar teknolojilerinin ve donanımlarının gelişimiyle yapay zeka uygulamalarının da yetenekleri artmış ve yeni metotlar ortaya çıkmıştır. 21. yüzyılda, hızla gelişen yapay zeka teknolojileri, mimarlara mimari tasarım süreçlerinde problem çözme konusunda yardımcı bir araç olma yolunda ilerlemektedir. Yapay zeka, normalde görsel algılama, konuşma tanıma ve diller arası çeviri gibi insan zekası gerektiren işleri yapabilen bir bilgisayar sistemidir. Matematiksel formüller ile doğrudan çözülmesi imkansız olan sorunların çözümünde, bilginin işlenerek karmaşık karar alma ve yorumlama işlerinde kullanılmaktadır. Yapay zeka, derin öğrenme ve görüntü işleme gibi tekniklerinde kullanılmasıyla özellikle uzmanlık ve tecrübe

gerektiren alanlarda “erken aşama karar almada... iş akışını kolaylaştırabilmektedir” (Lu Pengzhen, 2012). Bir başka ifade ile yapay zekâ kullanımındaki temel olgunun, verilerin tecrübe ile elde edilmiş doğru/yanlış yorumlamaları ile en az bir uzman kadar tutarlı ve doğru karar verme sürecini oluşturduğu söylenebilir. Mimari tasarım süreci de yapay zekâ sistemlerinde olduğu gibi bir ağaç algoritmasına sahip karar verme süreçlerinden meydana gelir. Analizler, toplanan girdiler, bağlam, kararlar, konsept bu ağaç algoritmasının dallarını oluşturur. Mimar tıpkı yapay zekâ algoritmalarında olduğu gibi ağacın dallarını taramaya başlar ve taramanın sonunda en uygun tasarım kararını verir. Ancak mimari tasarımda bu dalların yönelimi öznel tercihlerle kurulurken yapay zekâ ona tanımlanan nesnel doğru yanlış verilerine göre tercihlerini yapar.

Mimarlar tasarım sürecinin başlangıcında, bir yandan yapının mimari tasarım kararlarını alırken, bir yandan da taşıyıcı sistem kurgusunu oluşturmak zorundadır. Bu kurgunun en uygun biçimde yapılabilmesi için taşıyıcı sistem türlerini ve özelliklerini yeterince bilinmesi, bunların doğru seçilmesi ve doğru yerlerde kullanılması gerekmektedir. Mimari tasarımın erken aşamasında taşıyıcı sistem kurgusunun iyi düşünülmemesi, uygulama projesi aşamasında revizyonlarla karşılaşılmasına sebep olmaktadır. Taşıyıcı sistem kurgusunda yapılan büyük revizyonlar çoğu zaman mimari tasarımın da büyük ölçüde değişimine sebep olmaktadır. Bu değişiklikleri en aza indirgeyebilmek için erken aşamada mimarların taşıyıcı sistem kararlarını doğru alması gerekir. Ancak, deprem riskinin yüksek olduğu Türkiye gibi ülkelerde, deprem yönetmeliklerinin uygulanması zorunludur. Bu durumlarda mimarlar taşıyıcı sistem kararlarını tek başlarına alırken oldukça zorlanmakta ve yardıma ihtiyaç duymaktadırlar. Mimarın, tasarım sırasında doğru kararı verebilmesi için ya ekibinde bir inşaat mühendisinin bulunması ya da strüktürel analiz programlarını çok iyi kullanabilmesi ve yorumlayabilmesi gerekmektedir. Bu aşamada, söz konusu unsurların bulunmadığı şartlarda yapay zekâ ve yapay zekâ uygulamalarının kullanılıp kullanılmayacağı sorusu akla gelmektedir.

Çalışma kapsamında, yapay zekânın ve yapay zekâ metotlarının kullanıldığı alanlar incelenmiş, mimarlık alanında kullanılabilecek yöntemler tartışılmıştır. Araştırma sonucunda yapay zekânın karar vermek için verileri kullanma yeteneği ve önerilerinin, özellikle bir mimari projenin ilk aşamasında, tasarım süreci için çok önemli olduğu görülmüştür. Ayrıca, tasarımın ilk evrelerindeki eskiz vb. iki boyutlu

çalışma metotları göz önünde bulundurularak, yapay zekâ çalışma alanı içerisindeki görüntü işleme, görüntü sınıflama ve derin öğrenme metotlarının (Şekil 1) mimarlık ve inşaat alanlarında kullanımları araştırılmış; görüntü işlemenin, dijitalleştirilmiş vektörel çizimlerden ziyade, fotoğraf üzerinden hızlıca değerlendirme yapma imkânları üzerinde durulmuştur. Literatürdeki farklı disiplinlerde yer alan derin öğrenme ve görüntü işleme ile çözülen problemler incelenerek aynı metotların mimari alanda sağlayacağı faydalar tartışılmıştır. Bunlar ile birlikte tasarımın ana kararları arasında yer alan taşıyıcı sistem kurgusunun derin öğrenme, görüntü işleme ve görüntü sınıflandırma ile düzenlilik/düzensizlik durumunun bir uzmanın plana bakarak inceleyebildiği gibi değerlendirilmesinin mümkün olup olmadığı araştırılmıştır.



Şekil 1: Yapay Zekâ Çalışma Alanları (Mills, 2016)

## 1.2. Araştırmanın Amacı ve Önemi

Bu araştırmanın amacı, hem mimari tasarımın erken aşamasında depreme dayanıklı mimarlık bilinciyle taşıyıcı sisteme dair doğru kararlar alınmasını sağlamak hem de proje aşamasında gerçekleştirilecek beklenmedik revizyonları önlemeye yardımcı olmaktır. Bu amaçla ön tasarım evresinde, mimara projenin taşıyıcı sisteminin düzensizlik durumları hakkında fikir verebilen bir Düzensizlik Kontrol Asistanı (DK-Asistanı) oluşturulmuştur. Bu asistan, Türkiye Bina Deprem Yönetmeliği”, R.G. Tarih: 18 Mart 2018, Sayı: 30364’ da belirtilen düzensizlik durumlarını esas alarak, projeyi resim üzerinden bir uzman gibi okuyabilen ve projenin taşıyıcı sistemi hakkında yorum yapabilen bir yazılım uygulamasıdır. Deprem Yönetmeliği planda ve düşeyde olmak üzere iki tür düzensizlikten bahsetmektedir. Bu çalışmaya plandaki düzensizlik durumlarının ilk maddesi olan “burulma düzensizliği” kontrolü ile başlanmıştır. DK-Asistanı burulma düzensizliğini görüntü sınıflama yöntemi ile plan üzerinden değerlendiren bir prototip olarak geliştirilmiştir.

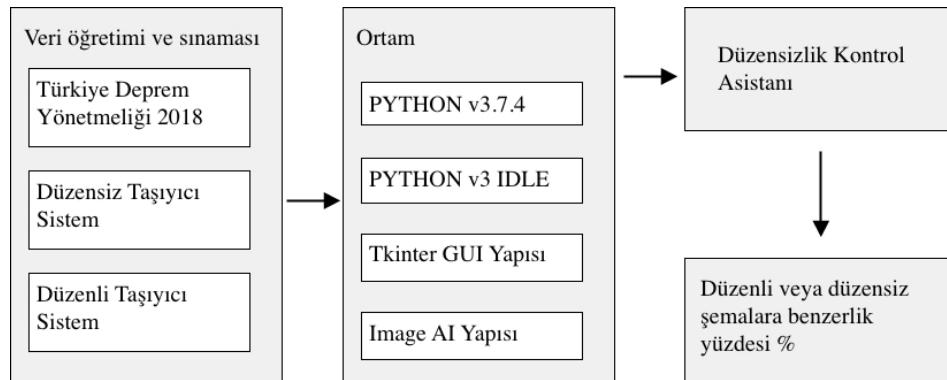
## 1.3. Araştırmanın Yöntemi

Taşıyıcı sistemin düzenli ya da düzensiz olduğuna dair bilgiyi verecek olan DK-Asistanını oluşturmak için makine öğrenimi metotlarından derin öğrenme yöntemleri kullanılmıştır. Bu metot ile makineye, seçilen doğru ve yanlış örneklerden bir veri seti girilmiş ve makineden örnekleri inceleyerek, verilen yeni proje hakkında doğru ve yanlış şemalarla benzerliğini değerlendirebileceği bir mantık kurması istenmiştir. Bir başka ifade ile derin öğrenme metodu ile makineye düzenli ve düzensiz plan şemaları öğretilmiş, görüntü sınıflamaya da önerilen planlar makine tarafından okunmuştur. Böylelikle bir girdi olarak verilen planın taşıyıcı sistemi hakkında uzman gibi yorum yapan ve mimara erken aşamada taşıyıcı sistem kurgusu için yardım eden bir araç oluşturulmuştur.

Çalışmaya 18 Mart tarihli R.G., sayı 30364 yer alan Türkiye Bina Deprem Yönetmeliği’ndeki ölçütler esas alınarak başlanmıştır. Bu yönetmelikte taşıyıcı sistem düzensizlikleri temel olarak, plan düzleminde ve kesit düzleminde düzensizlikler olmak üzere iki bölümde incelenmektedir. Plan düzlemindeki düzensizlik durumları “burulma düzensizliği”, “döşeme süreksizliği” ve “planda çıkıntılarının bulunması” olarak belirtilirken, düşeydeki düzensizlik durumları “Komşu Katlar Arası Dayanım Düzensizliği”, “Komşu Katlar Arası Rijitlik Düzensizliği” ve “Taşıyıcı Sistemin

Düsey Elemanlarının Süreksizliđi” olarak üç ařamada incelenmektedir (TBDY, 2018). Tez kapsamında altı farklı veri modeli oluşturularak, yapı planında olabilecek düzensizlik durumlarından “burulma düzensizliđini” kontrol eden bir uygulama kurgulanmıřtır. Daha sonra uygulamayı oluşturmak için akademik alanda en çok kullanılan “PYTHON” programlama dili ve yine Python programlama dili ile sunulan “PYTHON IDLE; Integrated Development and Learning Environment (Entegre Geliřtirme ve Öğrenme Ortamı)” kullanılmıřtır (Andrzej Kapanowski, 2014). Söz konusu yazılım ürünü yapılırken “Image AI 2.0.3-Framework” çalışma kütüphanesinden yararlanılmıřtır (Olafenwa, 2019). Image AI, en geliřmiş yapay zeka metotlarını, yeni ve mevcut uygulamalara ve sistemlerine kolayca entegre edilebilen bir Computer Vision Python kütüphanesidir. Geliřtiriciler, öğrenciler, arařtırmacılar, eđitmenler ve uzmanlar tarafından, hızlı prototipler geliřtirmek için kullanılmaktadır (Olafenwa, 2019). Python ve Image AI ile tez kapsamında geliřtirilen uygulama, görüntü tanıma ve derin öğrenme metotları ile plan görüntüsü üzerinden yorumda bulunması istenmiřtir. DK-Asistanına daha önceden verilmemiř yeni planlar sunulmuř ve bu planlardaki taşıyıcı sistem řemalarının deprem yönetmeliđinde tanımlandığı řekliyle plan düzlemine göre düzenli veya düzensiz olup olmadıđını sorgulaması istenmiřtir. Sonuçlar göstermiřtir ki, DK-Asistanı kendisine sunulan herhangi bir taşıyıcı sistem řemasının yüzde kaç oranında düzenli ya da düzensiz olduđu bilgisini başarıyla verebilmektedir.

řekil 2’de uygulamanın akıř řeması görölmektedir.




řekil 2: DK-Asistanının Çalışma Diyagramı

## İKİNCİ BÖLÜM

### LİTERATÜR BİLGİSİ

#### 2.1. Yapay Zekâ Nedir?

Kavram olarak 1950’li yıllarda ortaya çıkan yapay zekânın literatürde ortak bir tanımı bulunmamaktadır. Günümüzde yapay zekâ, insanlar tarafından zeki davranış olarak nitelendirilen bir takım faaliyetlerin makineler tarafından yapılmasını inceleyen bir bilgisayar bilimleri dalıdır. Yapay zekâ hakkında literatürde geçen tanımları incelersek John McCarthy’ye (2019) göre yapay zekânın hedefi “insan gibi davranış gösteren makineler geliştirmektir”. Nabiyev (2018) ise yapay zekâyı, “bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği” şeklinde tanımlamaktadır. Bu tanıma göre yapay zekânın kullanım alanını, düşünsel yetenek gerektiren işleri birtakım veriler ile birlikte makinelere yaptırması olarak düşünmek mümkündür. Örneğin 1966 yılında Joseph Weizenbaum tarafından MIT Yapay Zekâ laboratuvarında oluşturulmuş bir doğal dil işleme bilgisayar programı olan Eliza Programı kullanıcıların verdiği cevaplara göre yeni sorular sormakta veya cevaplamaktadır (Weizenbaum, 1966). Programın çalışma kurgusu, kullanıcının girdiği cümlelerin içinde bulunan anahtar kelimeleri saptayarak, önceden tanımlanmış olan cümlelerden birini konuşmanın devamına ekler ve kullanıcı ile etkileşime girer. Güncel bir örnek olan Apple Bilgisayar Teknolojileri Şirketinin ürünlerinde bulunan *Siri* Asistanı yazılımı, temel olarak *Eliza* ile aynı mantıkta çalışmaktadır. Kullanıcı tarafından gelen birtakım verileri analiz ederek ortaya insan davranışına benzeyen bir biçimde sonuçları yansıtır. Yapay zekânın çalışma alanları Şekil 3’de görülmektedir.



**Şekil 3 Yapay Zekanın Çalışma Alanları, Mattab, M. (2019).**

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

Yapay zekâ, insanlar gibi düşünen ve hareket eden aynı zamanda akıllı davranışların otomasyonu ile ilgilenen bir kavramdır. Yapay zekâ hakkındaki tanımlamalar dört gruba ayrılmaktadır. Bunlar, insan gibi düşünen makineler (*thinking humanly*), insan gibi davranan makineler (*acting humanly*), rasyonel düşünen makineler (*thinking rationally*), rasyonel davranan makinelerdir (*acting rationally*) (Russell & Norvig, 2010, s. 2).

### **2.1.1. İnsan Gibi Davranan Makineler**

İnsan gibi davranan makineler fikrinin temeli, sorulan sorulara makine tarafından verilen cevapların insanlar tarafından ayırt edilememesi olarak özetlenebilir. İnsan gibi davranan makineler kavramı ilk olarak 1950 yılında John McCarthy ve arkadaşları tarafından bir akademik konferansta önerilmiştir. Bu fikir matematikçi Alan Turing tarafından test edilmiştir. Bu testin adı literatürde “Turing Testi” olarak bilinmektedir. Testin sonucunda makinelerin insanlar gibi düşünmesini ve öğrenmesini sağlamanın mümkün olduğu ortaya çıkmıştır. Turing testinde, makinelerin insan olarak tepki

gösterip gösteremediğini tespit edebilmek için pragmatik bir yaklaşım kullanılmıştır (Smith, McGuire, Huang, & Yang, 2006).

Turing testi iki oyuncu ve bir hakemden oluşan deneysel bir soru cevap oyunudur. Oyunculardan biri bilgisayardır. Diğer oyuncu ve hakem ise insandır. Hakem, ekran ve klavye kullanarak oyunculara birtakım sorular yöneltir. Oyuncular tarafından verilen yanıtlara göre hakem, bilgisayar olan oyuncuyu bulmaya çalışır. Cevaplar insanlara sorulduğunda insanların vereceği türdendir. Örneğin oyunculara bir toplama işlemi sorulduğunda, makine cevabı vermeden önce beklemektedir; ya da makineden bir şiir yazması istenildiğinde, “şiir yazmayı beceremem” şeklinde cevaplar vererek bir insan profili ortaya koymaktadır (Russell & Norvig, 2010, s. 3-4).

### **2.1.2. Rasyonel Düşünen Makineler (Düşünce Yasaları Yaklaşımı)**

Yapay zekâ çalışmalarında düşünce yasaları yaklaşımının temeli Aristoteles’e kadar geri götürülmektedir. Bu yaklaşıma göre, Aristoteles “doğru düşünceyi”, yani reddedilemez akıl yürütme süreçlerini kodlamaya çalışan ilk kişilerden biridir. Aristoteles’in tasımları, doğru önermeler verildiğinde daima doğru sonuçlar veren argüman yapıları için şablonlar sağlamıştır. Örneğin “Sokrates bir insandır; bütün insanlar ölümlüdür; o halde, Sokrates ölümlüdür.” Bu düşünce sistemi “mantık” denilen çalışma alanının da temeli oldu ve daha sonra 19. yy mantıkçıları dünyada var olan tüm nesnelere ilgili ifadeleri ve nesnelere arasındaki ilişkilere yönelik formüller oluşturmaya çalıştılar. 1965 yılından sonra, mantık (matematik) dili ile formüle edilebilen çözülebilir her problemi ilke olarak çözebilen yapay zekâ programları ortaya çıkmaya başlamıştır. Ancak bu yaklaşımın, giren bilgi doğruluğunun kesin olmaması, değişkenlerin mantık dilinde formüle edilmesinin kolay olmaması ve bir problemin ilke olarak çözülebilir olması ile pratikte (uygulamada) çözülmesinin arasında büyük fark olması gibi birtakım sorunlu yönleri vardır. (Russell & Norvig, 2010, s. 3-4).

### **2.1.3. İnsan Gibi Düşünen Makineler (Bilişsel Modelleme Yaklaşımı)**

Bilişsel modelleme yaklaşımı temelde insanın nasıl düşündüğünün anlaşılması üzerinde yoğunlaşır. Bu nedenle bu yaklaşım yapay zekâ uzmanları ile psikoloji alanının bilim insanlarının bir arada çalışmasını gerektiren bir yaklaşımdır. Eğer bir programın insan gibi düşündüğü söylenecekse, öncelikle insanların nasıl



düşündüğünün belirlenmesi gerekir. İnsanların nasıl düşündüğünü ve insan zihninin yapısını kapsayıcı bir teori ile ortaya koyduktan sonra ise, zihnin çalışma sistemini bir bilgisayar programı olarak ifade edebilmek mümkün hale gelebilir. Bu yaklaşıma göre programın girdi-çıkı davranışına karşılık gelen davranışları, insan davranışları ile eşleşirse, bu programın bazı mekanizmalarının insanlarınkı gibi çalışabileceği söylenmektedir. (Russell & Norvig, 2010, s. 3-4).

#### **2.1.4. Rasyonel Davranan Makineler (Rasyonel Etmen Yaklaşımı)**

Rasyonel davranan sistemler yaklaşımının temel olgusu etmendir (İng. *agent*). Etmen kavramı Latince eylemde bulunmak anlamına gelen “agere” kelimesinden türemiştir ve “bir şeyi yapan, eyleyen” anlamındadır. Buna karşılık “rasyonel etmen” ise, davranışlarında rasyonel olabilen anlamındadır. Bir başka ifade ile, belirli durumlarda *en iyi sonuca* ulaşmak için eyleyen ya da belirsiz durumlarda *mümkün olan en iyi sonuca* ulaşmak için eyleyen anlamına gelmektedir. Bu yaklaşım insan gibi düşünen makineler yaklaşımındaki doğru sonuç çıkarmaya benzemekle birlikte ondan daha farklıdır. Bazı durumlarda rasyonel davranmak, düşünüp karar vererek doğru sonuç çıkartmayı içermez. Sıcak bir nesneye elimiz değdiğinde refleks ile elimizi oradan çekmemiz, rasyonel bir eylem olmasına karşılık, sonuç çıkartılarak yapılan bir eylem değildir. Bu nedenle rasyonel davranan makineler yaklaşımı daha olumlu kabul edilmektedir. Bu kategoriye giren bilgisayarlar, otonom kontrole sahip olarak kendi kendilerini yönetmeli, çevreyi algılamalı, varlığını sürdürmeli, değişen koşullara uyum sağlamalı ve bunlar ile birlikte hedefleri gerçekleştirebilmelidir. Rasyonel etmen mevcut durumdan en iyi performansı sağlayabilecek şekilde davranan sistemlerdir (Russell & Norvig, 2010, s. 4-5)

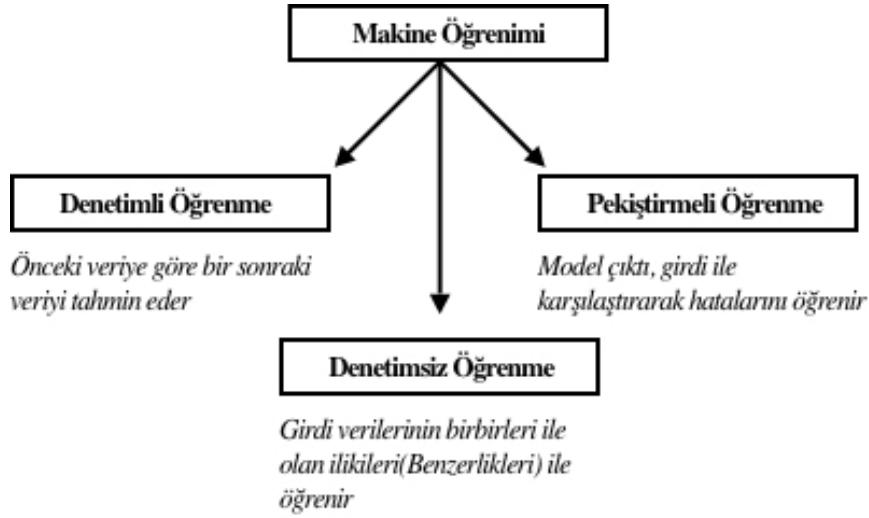
## **2.2. Makine Öğrenimi**

Makine öğrenimini tanımlayabilmek için öncelikle büyük verinin ne olduğunu ve makine öğreniminde nasıl kullanıldığını belirlemek önemlidir. Büyük veri, toplanan ve depolanan verilerdeki artışın bir sonucu olarak ortaya çıkan bir terimdir. Bu verilerin nasıl toplandığını bir örnek ile ifade etmek gerekirse, kameralardan alınan görüntüler, sensörler, internet ortamındaki yazılı ve görsel bütün veriler, sosyal amaçlı oluşturulmuş kişisel paylaşımlar ve öz veriler büyük veriyi oluşturmaktadır (Vasilev ve d., 2019).

Makine öğrenimi (*machine learning*), bilgisayar sistemlerinin kullanıcı tarafından açık bir emir veya talimat belirtmeksizin önceden tanımlanmış belli bir görevi yerine getirmek için istatistiksel modellerin bilimsel bir çalışmasıdır (Vasilev ve d., 2019). 1980’li yıllarda ilk kez ortaya çıkan bu tanım belli veri kalıplarına ve istatistiki çıkarımlara dayanarak çalışan bir yapay zekâ sistemini anlatır. Örneğin, bir e-posta sürekli olarak kullanıcı tarafından istenmeyen posta olarak işaretlenir ise makine belli bir veri bütününe eriştiğinde aynı adresten gelen e-postalar kullanıcıya danışmadan otomatik olarak istenmeyen kutusuna ayrılacaktır (Bishop, 2006).

Makine öğrenimi yapay zekâ araştırma alanının bir alt dalı olarak görülmektedir. Makine öğrenim algoritmaları, verilen bir görevi gerçekleştirmek üzere açıkça programlanmamış olsa da karar vermek için öngörülere dayanarak istatistik temelli bir mantık oluşturur. Bu mantığı kurabilmek için “eğitim verisi” olarak bilinen kullanıcı tarafından oluşturulmuş örnek veri yığınının dayanan matematiksel bir model oluşturmak gerekir (Koza, Bennet, Andre, & Keane, 1996). Büyük bir veri yığınının yararlı bilgiyi çekip çıkarabilmek için ihtiyacı karşılayacak değerli verilerin elde edilmesi işlemine “veri madenciliği” denilmektedir. Veri madenciliği, makine öğrenmesi içindeki bir çalışma alanıdır ve denetimsiz öğrenme yolu ile keşifsel veri analizine odaklanmaktadır (Friedman, 1998).

Makine öğrenimi alanında yapılan ve uygulanan en çok çalışma görüntü tanıma işlemidir. Görüntünün makineye tanıtılması için binlerce aynı özelliklere sahip görüntülerin ve bunların motiflerin tanıtılması gerekir. Makine motifleri ve görüntüyü temsil eden piksellerin konumlarını ve değerlerini öğrenerek, sunulan görüntünün ne olduğunu anlar. Makine öğrenimi, bulanık mantık, yapay sinir ağları, derin öğrenme başlıkları altında incelenmektedir. Makine öğrenimi stratejileri üç gruba ayrılır. Bunlar, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir (Atalay & Çelik, 2017). Şekil 4’te makine öğrenim modelleri gösterilmiştir.



**Şekil 4 : Makine Öğrenim Türleri**

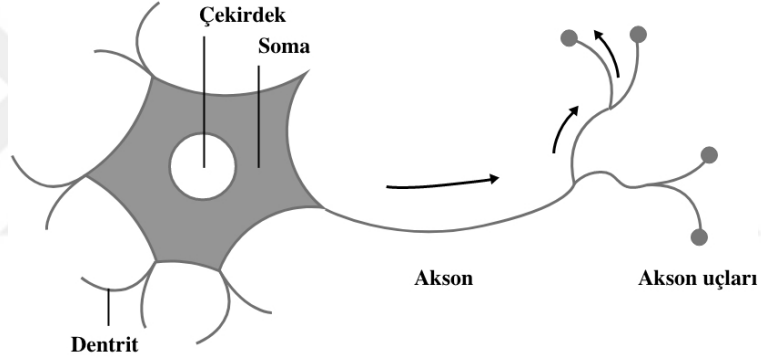
Denetimli öğrenmede makine, sunulan girdiyi daha önceki çıktılar ile karşılaştırarak öğrenmektedir. Her bir girdi giderek iyileşen çıktı sonuçlarına göre öğretilir. Denetimsiz öğrenme ise çıkış değerleri ile olan bağlantıyı keserek yalnızca girdi değerlerini dikkate alır. Buradaki amaç girdi değerlerini birbiri ile karşılaştırarak aralarındaki ilişkiyi saptamaktır. Bu sayede birbirine yakın değere sahip girdiler otomatik olarak kümelenir ve girdi, oluşturulan kümeye göre tespit edilmiş olur. Pekiştirmeli öğrenmedeki amaç ise elde edilen çıktının girişe göre karşılaştırarak iyi veya kötü olarak ölçüt sunmasıdır (Atalay & Çelik, 2017).

### 2.2.1. Bulanık Mantık

1965 yılında Zadeh tarafından ileri sürülen bulanık mantık, 100% doğru veya 100% yanlış gibi kesin sonuç çıkartmak yerine biraz doğru, biraz yanlış şeklinde gruplar arası benzerlikleri ifade eden bir sistemdir. Bulanık mantık küme teorisinde üyelik derecesi kavramını ele alır. Örneğin, gençler kümesine 25 yaşındaki bir insan %100 üye iken, 60 yaşındaki bir insan %30 üyedir şeklinde ifadeleri vardır. Bulanık mantığın gerçek hayat olaylarına daha iyi çözüm önerilerinde bulunabileceği düşünülmektedir (Pirim, 2011).

### 2.2.2. Yapay Sinir Ağları (Artificial Neural Network)


Yapay sinir ağları, yapısal ve kavramsal olarak insan biyolojik sinir hücresinden ilham alarak birbirlerine bağlı yapay sinirlerden oluşmaktadır. Doğrusal olmayan bir modeldir ve bir girdi seti ve tek bir çıktı içermektedir (Nabiyev, 2016). Beynimizde yer alan sinir ağları karmaşık öğrenme ve yorumlama yeteneğine sahiptir. 1943'te McCulloch ve Pitts bu karmaşık sistemi matematiksel olarak taklit ederek yapay zekânın ve makine öğreniminin temelini oluşturmuşlardır (Ertel, 2009). Yapay sinir ağları, kontrol ve sistem tanımlama, görüntü ve ses tanıma, tahmin ve kestirim, arıza tespiti gibi alanlarda kullanılmaktadır (Pirim, 2011). Özetle, yapay sinir ağları, bir insan beyninin işleyişini ve basit gözlemlerle yeni kurallar oluşturma yeteneğini taklit etme. Aksonlar gelen bilgiyi (sinapsis) de işlemekten geçirerek diğer sinir hücrelerinin dentritlerine iletir (Şekil 5) (Yılmaz A. , 2018).



Şekil 5: Biyolojik Sinir Ağı (Yılmaz A. , 2018)

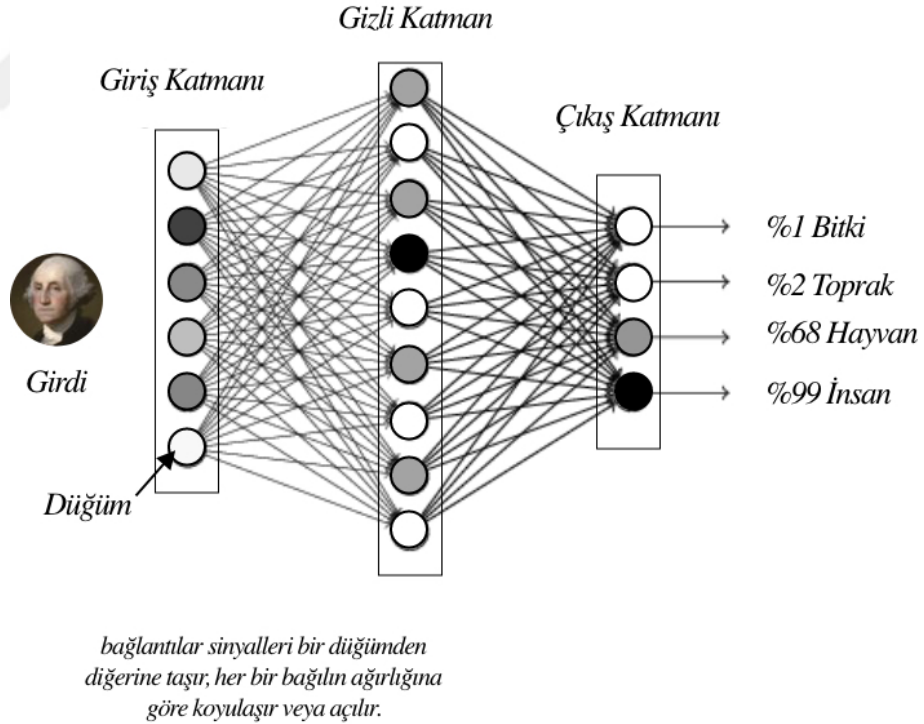
Bu prensip ile birlikte çok katmanlı sinir ağlarını açıklamak gerekirse, sinir hücreleri akson uçları (sinapsis) ve dentrit ile birbirine bağlıdır. Bu yapay sinir ağında  $f(x)$  fonksiyonun sonucunda çıkardığı  $y$  değeridir.

Şekil 6'da yapay sinir hücresi görülmektedir. Buradaki fonksiyonları inceleyecek olursak, sinyalin girişi  $x(i)$  vektörü ile gösterilmiştir.  $w(i)$  ise girdinin ağırlığını göstermektedir. Girdi değeri, diğer adı ile sinyal değeri,  $w$  ile belirtilmiş olan ağırlıklar ile çarpılarak veri akışı gerçekleşir (Yılmaz A., 2018).



**Şekil 6: Yapay Sinir Hücresi Şeması**  
(Yılmaz A. , 2018)

Şekil 7’de tek katmanlı bir yapay sinir ağının temel yapısı görülmektedir. Daireler YSA’nın düğümlerini diğer adı ile nöronlarını göstermektedir. Basit sinir ağı modelinde, 3 katman bulunmaktadır. Bunlar giriş katmanı, gizli katman ve çıkış katmanıdır. Giriş katmanında girdinin piksel değerleri belirlenir. Gizli katmanda imajın renk ve piksel dağılımları incelenir. Çıkış katmanında ise modele daha önce öğretilmiş olan imajların özellikleri ile karşılaştırma yaparak sonuç vermektedir.




**Şekil 7: Tek Katmanlı Bir Yapay Sinir Ağının Temel Yapısı**  
(Waldrop, 2020)

### 2.2.3. Derin Yapay Sinir Ağları ve Derin Öğrenme

Derin öğrenmenin temelini oluşturan yapay sinir ağları 2010'lu yıllarda kullanılmaya başlayan derin yapay sinir ağları veya hiyerarşik sıralı öğrenme kavramı, bir makine öğrenim metodudur (Benjamin ve d., 2013). Temelde derin öğrenme makine öğreniminin bir alt kümesidir. Ancak derin öğrenmenin makine öğrenimine göre yetenekleri farklılaşmaktadır. İnsan düzeyine yakın görüntü sınıflandırması (insan kadar hassas görüntü tanıma ve sınıflandırma), insan düzeyinde konuşma tanıma, insan düzeyinde metin okuma ve seslendirme gibi konuları kapsamaktadır (Chollet, 2018).

Derin öğrenme, makine algısı ve biçimsel akıl yürütme gibi doğal dil anlayışı dışında çok çeşitli sorunlarda uygulanmaya başlanmıştır. Hakkında hala araştırmaların yapıldığı deneysel bir alan olan derin öğrenmenin birçok bilim alanında ve yazılım geliştirmede etkili olduğu görülmektedir. Derin öğrenme yapıları, çok katmanlı yapay sinir ağlarıdır. Derin terimi ise çok katmanlı olan sinir ağını ifade etmektedir. Şekil 7'de gösterildiği üzere klasik yapay sinir ağları sadece iki veya üç katmandan oluşmaktadır. Derin ağlar ise yüzlerce katmana kadar çıkabilirler (Şekil 8') (Mathworks, 2020).



Şekil 8 Derin Yapay Sinir Ağı (Waldrop, 2020)

Yeni bir derin öğrenme yapısı oluşturmak için verilerin sınıflandırılabilir bir biçimde ayrılması gerekmektedir. Oluşturulacak yeni derin öğrenme yapısı bir veriyi nasıl öğreneceğini bilmediğinden bu yöntem milyonlarca veri ve yüzlerce sınıfa ihtiyacı olan özel uygulamalarda kullanılır. Veri boyutunun büyük olmasından dolayı, sıfırdan başlayarak bir derin öğrenme yapısı oluşturulamaz. Bunun yerine *GoogLeNet*, *InceptionV3*, *DensNet*, *Microsoft ResNet* gibi var olan derin öğrenme modelleri kullanılır. Bu modellere daha önceden eğitilmiş *pre-trained* modeller denir. Son bir veya iki katman çıkartılarak üzerine yeni model kurulur. En büyük avantajı ise modelin, zaten bir veriyi nasıl öğreneceğini bildiği için az veri ile tutarlı sonuçlar verebilmesidir (Mathworks, 2020).

DK-Asistanının oluşturulmasında model olarak görüntü işlemede daha etkili olan *ResNet* modeli kullanılmıştır. *ResNet* modeli diğer hazır model yapılarından daha derin ve tutarlı sonuç vermektedir. *ResNet*, 2015 yılında *ImageNet* yarışmasını kazanan 34 katmanlı ilk derin yapay sinir ağı yapısıdır (Mathworks, 2020).

#### 2.2.4. Derin Öğrenme Mimarileri

Derin öğrenme mimarileri *hibrit*, *ayırıcı* ve *üretken* olmak üzere 3 grupta incelenir.

*Hibrit mimariler*, ayırıcı ve üretken mimarilerin birleşmesinden oluşan mimaridir. Nesneleri sınıflandırma işleminin yanı sıra optimizasyonu da hedefler. *Üretken mimariler*, nesnenin analizini ve sentezini gerçekleştiren, verilerin birbirleri ile alakalı özelliklerini bulan mimaridir. *Ayırıcı mimariler* ise, yalnızca nesnelere kategorilendirilmesi amacı ile kullanılmaktadır (Deng, 2012).

Derin öğrenme mimarileri arasında en çok kullanılan mimariler, derin ileri-beslemeli ağlar (*Deep Feed-Forward Networks*), tekrarlayan ağlar (*Recurrent Networks*) ve ileri beslemeli konveksiyonel sinir ağıdır (CNN). Bu çalışmada bilgisayarlı görmede etkili olan CNN mimarisi dolaylı olarak *ImageAI* yapısı altında kullanılmıştır.

### 2.2.5. Konveksiyonel Sinir Ağı Sınıfı ve Görüntü İşleme

Konveksiyonel sinir ağı, derin öğrenmede evrişik sinir ağıları olarak bilinen (*CNN* veya *ConvNet*), derin öğrenmenin en popüler algoritmalarından biridir. CNN'ler sınıflandırma işini doğrudan görüntü, video, metinden veya ses üzerinden yapabilmektedir. Bu CNN sınıfı görüntü ve video tanıma, öneri sistemleri ve görüntülerin analiz gibi uygulamalarda kullanılmaktadır. (Goodfellow, Bengio, & Courville, 2016).

CNN'ler özellikle nesnelere, yüzler ve sahneleri analiz etmek ve desen bulmak için kullanılır. Bu model, görüntüleri sınıflandırmak ve sınıflandırma sürecini otomatikleştirmek için hazır kalıplar kullanır. Doğrudan görüntü verileri ile CNN eğitilebilmektedir. Çalışma alanlarına örnek vermek gerekirse, kendi kendini süren araçlar ve yüz tanıma uygulamaları gibi nesne tanıma ve bilgisayarla görme gerektiren uygulamalar için CNN'ler kullanılır (Mathworks, 2020).

Şekil 8'de görüldüğü üzere, derin yapay sinir ağıları, görüntünün farklı özelliklerini tespit etmeyi öğrenen yüzlerce katmana sahip olur. Girdi olarak sunulan görüntü bir dizi filtreleme işleminden geçirilir. Filtreler, parlaklık ve kenarlar gibi çok basit özellikler olarak başlayabilir ve nesneyi benzersiz bir şekilde tanımlayan özelliklerin karmaşıklığını artırarak daha detaylı bir öğrenim gerçekleştirirler.

CNN'lerin diğer görüntü sınıflandırma algoritmalarına göre en büyük avantajlarından biri, ön işlemden veya insanlar tarafından sağlanan önceki bilgilerden bağımsız olarak, büyük görüntü veri tabanları ve büyük miktarlarda etiketlenmiş bilgiyi işleyerek, girdilerini en doğru ve etkili bir şekilde nasıl değerlendireceklerini kendi başlarına öğrenmeleridir (Goodfellow, Bengio, & Courville, 2016).

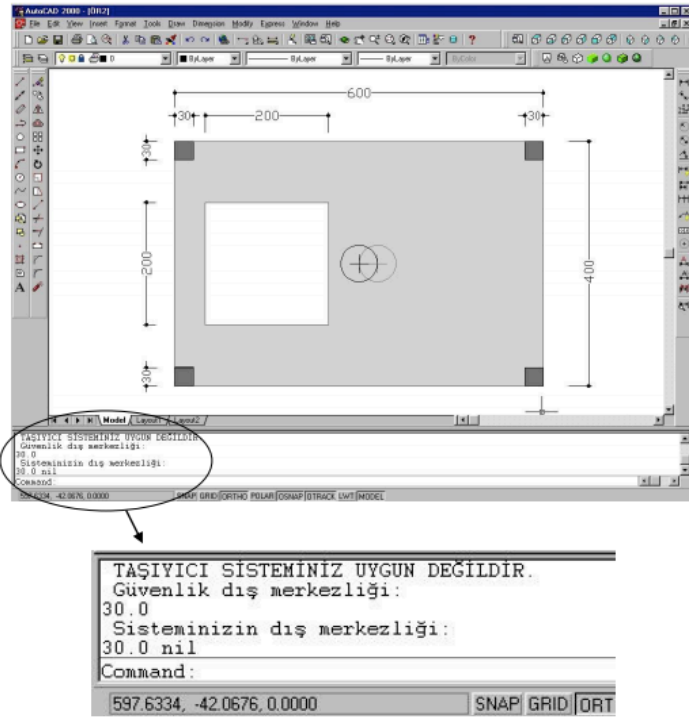
En baştan başlayarak bir CNN modeli oluşturmak çok maliyetli bir işlemdir. Çalışmalarda ve araştırmalarda daha önceden eğitilmiş olan modeller kullanılır. Bu modellerin geniş özellik kümesi bir sonraki modele aktarılarak yeni bir model oluşturulur. Bu yöntemle öğrenme aktarması (*Transfer Learning*) denilmektedir. Öğrenme aktarması daha önceden eğitilmiş bir ağı üzerine eğitilmesidir. Örneğin, milyonlarca görüntü üzerinde eğitilmiş bir ağı alabilir ve yalnızca yüzlerce görüntü kullanarak yeni nesne sınıflandırması için yeniden eğitilebilmektedir. Söz gelimi CNN zaten bir görüntüyü nasıl öğreneceğini saptamış ve milyonlarca görüntü işleyerek özellik kümesini genişletmiştir (Mathworks, 2020).



## ÜÇÜNCÜ BÖLÜM

### DEPREME DAYANIKLI MİMARİ TASARIMDA DERİN ÖĞRENME VE GÖRÜNTÜ SINIFLANDIRMA UYGULAMALARININ KULLANIMI

Mimarlıkta yapay zekâ, uzman sistemler, genetik programlama ve bulanık sistemler olarak kullanılmaktadır. Literatür incelendiğinde, mimarlık alanındaki yapay zekâ çalışmaları bina tasarım sürecinin erken aşamalarında fiyatlandırma tahmini, şema tasarımı, plan tasarım optimizasyonu ve projenin denetlenmesi gibi konularda yapılmıştır. Bu alanda yapılan çalışmalardan ilki İdemen'in 2003 yılındaki çalışmasıdır. İdemen (2003) tezinde, Deprem Yönetmeliği'nde belirtilen A1 düzensizliği olarak tanımlanan burulma düzensizliğini temel almakta ve yapay zekâ uygulamalarından yararlanarak binaların rijitlik ve ağırlık merkezlerinin kontrolünü yapmaktadır. İdemen'in uygulaması Şekil 9'da gösterilmiştir.



Şekil 9: Autocad Üzerinde Çalışan A1 Düzensizlik Uygulaması (İdemen, 2003)

Autocad programı ortamında LISP kullanarak oluşturulan program başka programlar altında çalışmaktadır. Diğer bir çalışma Tuzcuoğlu'nun 2003 yılındaki çalışmasıdır. Tuzcuoğlu (2003) makalesinde, kullanımı artan yapay zeka yöntemlerinin varlığından ve yapay sinir ağlarının katkılarında bahsederken, bunları çalışma prensiplerine göre uzman sistemler, olguya dayalı açıklama ve küme teorisi olmak üzere üç grupta incelemiş ve türlere göre güçlü ve zayıf yönlerini araştırmıştır. Ayrıca, küme mimarisinden de söz eden çalışma bulanık küme kuramının inşaat mühendisliğinde kullanılabileceğini de anlatmaktadır.

Günaydın ve Doğan(2014) ise çalışmalarında bina tasarım süreçlerinin erken aşamalarında maliyet tahmin problemlerini çözmek için yapay sinir ağı metodunun kullanımını araştırmışlardır. Çalışma örnek olarak Türkiye'deki 4-8 katlı konut yapılarının betonarme yapı sistemlerinde metrekare maliyetini tahmin etmektedir. Çalışmada maliyetleri belirlemek için sekiz farklı tasarım parametresi kullanılmıştır. Modeli eğitmek ve sınamak için otuz farklı projeden maliyet ve tasarım verileri alınmıştır. Kurulan model, %93 lük bir tutarlılıkla başarılı olmuştur (Günaydın & Doğan, 2004).

Yine yapı alanında Lu ve arkadaşları (2012) evrimsel hesaplama, yapay sinir ağları, bulanık sistemler, uzman sistemler ve derin öğrenme ile kaos teorisi gibi yapay zeka uygulamalarını ve son zamanlarda gelişen yöntem ve teorileri özetlemektedir. Lu makalesinde matematiksel veya fizik formülleri ile çözülemeyecek problemleri karmaşık problemler olarak tanımlamaktadır. Çalışmada, yapay zeka başlığı altında yer alan genetik programlama, sürü teoremi, yapay sinir ağları, bulanık sistemler gibi yazar tarafından uzman sistemler olarak belirlenen sınıfların, erken aşamada, inşaat yönetiminde ve süre tahminlerindeki kullanımları incelenmiştir. Sonuç olarak Lu ve arkadaşları, bu yöntemlerin tecrübesi olmayan kullanıcılar için tecrübe gerektiren problemlerin çözümünde yardımcı olduğunu ve aynı zamanda tecrübeli kullanıcıların da iş akışlarını daha verimli hale getirdiği gibi faydalarının bulunduğunu vurgulamaktadır (Lu Pengzhen, 2012)

Başka bir çalışmada ise inşaat mühendisliğinde, karmaşık ve iyi anlaşılmayan problemlerin çözümünde geleneksel mühendislik programlarının yetersiz kaldığından bahsedilmektedir. Söz konusu çalışmada yapay zekadan yardım alarak tahmin, risk analizi, karar verme, kaynak yönetim optimizasyonu ve benzeri bir çok konuda

problemlerin çözüldüğü örnekler ile anlatılmaktadır (Patil, Patted, Tengai, & Jahagirdar, 2017).

Birbirine çok yakın iki disiplin olan inşaat mühendisliği ve mimarlık alanlarının herhangi birinde kullanılan yapay zeka uygulamalarının her iki disipline de faydalı olduğu bir gerçektir. Örneğin Bayboğan (2013) tarafından, her iki disiplinin de yararına olan bir uygulama olarak yapay zeka ve arı algoritması kullanılarak tip imar yönetmeliklerine göre arsa için en uygun tasarımı ve vaziyet planını üreten bir program yazılmıştır (Bayboğan, 2013). Waziri vd. (2017) ise çalışmalarında yapay sinir ağları ile yapım süreci maliyet tahmini, optimizasyon, zaman yönetimi, risk değerlendirmesi gibi matematiksel ve istatistiksel yöntemlerle çözülmesi zor olan problemleri incelemekte ve yapay sinir ağlarının, geleneksel programlara göre daha doğru ve güvenilir tahminler verdiğini savunmaktadırlar (Waziri, Bala , & Bustani, 2017). Wei ise yapay zeka ile mimari tasarımın bir arada kullanılmasına ilişkin mimari akıllı tasarım (MAT) modeli önermekte ve MAT modeline göre, mimari tasarım, analiz ve imalat üzerine uygulanan bir dizi yapay zeka yöntemini tartışmaktadır (Wei, 2018).

Bir diğer çalışmada ise Cudzik ve Radziszewski (2018), mimarlar tarafından kullanılan yardımcı araçların her zaman yapım sürecini ve tasarım sürecini etkilediğini vurgulamaktadır. Çalışma, yapay zekanın hesaplama ve simülasyon uygulamalarında nasıl kullanıldığından ve yeni hesaplama algoritmaları ile geometrik formların karmaşık yapısını ortaya çıkartıp bunları detaylandırabildiğinden bahsetmekte; küme zekası algoritması, evrimsel algoritmalar, yapay sinir ağı algoritmaları ve bunların mimarideki kullanımlarını Şekil 10 ve Şekil 11 ile örneklemektedir. (Cudzik & Radziszewski, 2018).




**Şekil 10: Makine Öğrenimi ile Oluşturulmuş Kolon Başlıkları (Cudzik & Radziszewski, 2018).**



Şekil 11: Sürü Zekası ile Oluşturulmuş Tasarım (Cudzik & Radziszewski, 2018).

Haun ve Zheng çalışmalarında, derin öğrenme planları okuyabilen ve GAN metodu ile daha önce okuttukları planlardan yeni planlar üreten bir sistemi tartışmışlardır. Llamas ve meslektaşları planlama ve şehircilikte daha verimli ve optimum tasarımlar ortaya çıkartmanın mümkün olduğunu söylemektedir (Llamas ve d., 2017). Yazarlar bu çalışmayı yaparken derin öğrenme ve GAN'dan yararlanmışır (Huang & Zheng, 2018). GAN (Generative Adversarial Networks) 2014 yılında *Ian Goodfellow* ve meslektaşları tarafından icat edilen bir makine öğrenme sistemleri sınıfıdır. Eğitilmiş bir model seti verildiğinde, verilen eğitim setini taklit etmeye çalışarak aynı istatistiklere ve özelliklere sahip yeni veriler üretmeyi öğrenen bir sistemdir (Goodfellow ve d., 2014).

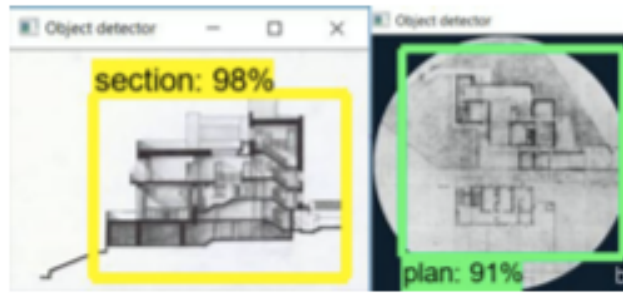


Şekil 12: GAN Kullanımı (Huang & Zheng, 2018)

Şekil 12'de görüldüğü üzere girdideki elemanları tanıyarak, yeni ve alternatif elemanlar üretmektedir (Huang & Zheng, 2018).

Radziszewski'nin yayınlamış olduğu *“Artificial Neural Networks as an Architectural Design Tool-Generating New Detail Forms Based On the Roman Corinthian Order Capital, 2017 (Mimari Tasarım Aracı olarak Yapay Sinir Ağları – Roma Korint Tarzı Kolon Başlığı Benzeri Yeni Detaylar Üretmek,”* başlıklı çalışmasında, Roma Kornit Tarzı Kolon başlıklarının geometrik şekillerinden oluşan bir veri seti ile YSA modeli oluşturmuştur. Yazar, bu setteki geometrik ilişkiler ile yeni geometrik şekiller oluşturarak, yapay zeka uygulamalarının etkisi üzerine bir tartışma yürütmüştür (Radziszewski, 2017).

Derin öğrenme ve görüntü üzerine bir diğer örnek ise Uzun & Çorakoğlu'nun (2019) yaptığı çalışmadır. Bu çalışmada piksel tabanlı mimari plan ve kesitlerin derin öğrenme yöntemi ile saptanması üzerine bir vaka çalışması yapılmıştır. Yazarlar, Şekil 13'te görüldüğü gibi mimari çizimleri, plan veya kesit, ya da el çizimi veya dijital çizim fark etmeksizin okuyan ve sınıflayan bir model geliştirerek derin öğrenme ve görüntü işlemenin kullanımını incelemiştir.



**Şekil 13: Eskiz Plan ve Kesit Çizimi (Uzun & Çorakoğlu, 2019).**

Jennifer ve meslektaşları ise 2019 yılında yaptıkları çalışmada, derin öğrenme ve görüntü sınıflandırma yöntemi ile mimari plan, kesit ve görüntüleri okuyabilen yeni bir CNN modeli oluşturmuşlardır. Bu yeni model ile büyük firmaların veya kurumların veri kütüphanelerinde yer alan bütün projeler otomatik olarak sınıflandırılmış ve dosyalanmıştır. Söz konusu CNN modelinin, bu sayede kurumların ve şirketlerin verilerini çok hızlı bir biçimde dosyalayarak, kurumlara zaman kazandırdığı saptanmıştır. Yazarlar, çalışmada örnek olarak Sydney Opera binasının (Şekil 14) kesit ve planlarını birbirinden ayıran bir CNN modeli oluşturmuşlardır. Şekil 14'da yapının çizimlerine göre CNN modelinin verdiği tahminler yer almaktadır (Jennifer, ve diğerleri, 2019).




Image: "12708\_00003.jpg"  
Prediction: Plan drawing with 93.48% confidence




Image: "12707\_00050.jpg"  
Prediction: Section drawing with 100.00% confidence




Image: "First\_Floor\_Plan\_(Sydney\_Opera\_House)\_(5373...)"  
Prediction: Plan drawing with 99.72% confidence




Image: "12708\_00041.jpg"  
Prediction: Section drawing with 100.00% confidence



Image: "Sydney-Opera\_planta\_vig-1024x695.jpg"  
Prediction: Plan drawing with 99.58% confidence














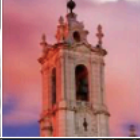

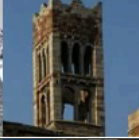

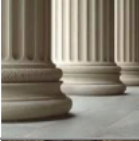

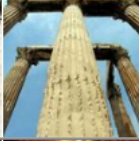

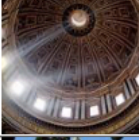
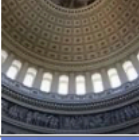










Image: "NRS12800-2\_a122\_000029.jpg"  
Prediction: Section drawing with 99.85% confidence

Şekil 14: Sydney Opera Binası Plan ve Kesitleri (Jennifer, ve diğerleri, 2019).

Llamas ve meslektaşları ise çalışmalarında, kültürel mimari eserleri derin öğrenme ve görüntü işleme yöntemi ile sınıflandırmışlardır. Yazarlar, mimari öğelerin ölçümleri sırasında çekilen görüntülerin doğru bir şekilde sınıflandırılması ve insan hatalarını minimuma indirmek için yapay zekâdan yararlanmışlardır. Girdi olarak verilen mimari görüntünün, hangi plan ve kesite ait olduğunu gösteren bir uygulama yapılmıştır. CNN mimarisi ile oluşturulan bu sınıflandırma uygulaması dijital dosyalama ve sınıflandırma işini otomatikleştirmiş, zaman ve efor tasarrufu sağlamıştır. Çalışmada kullanılan veri setleri ise kamuya açık hale getirilmiştir (Şekil 15) (Llamas ve d., 2017).

**Table 1.** Dataset samples of Cultural Heritage images used.

| Category                      | Examples  |   |  |   |   |
|-------------------------------|---|---|--|---|---|
| Altar<br>(829 images)         |   |   |   |   |   |
| Apse<br>(514 images)          |  |  |  |  |  |
| Bell tower<br>(1059 images)   |  |  |  |  |  |
| Column<br>(1919 images)       |  |  |  |  |  |
| Dome (inner)<br>(616 images)  |  |  |  |  |  |
| Dome (outer)<br>(1177 images) |  |  |  |  |  |

**Şekil 15:** Kültürel Öğelerin Veri Seti Örneği (Llamas ve d., 2017)



Yapılan literatür çalışmaları incelendiğinde mimarlık alanında yapay zeka ve derin öğrenme çalışmalarının son yıllarda arttığı görülmektedir. Literatürde, derin öğrenme ile mimari planların yapay zekâya öğretilerek yeni planların oluşturulması ve görüntü sınıflandırma yöntemleri ile mimari plan ve görüntülerin kategorilendirilmesi gibi konuların ağırlıklı olarak tartışıldığı gözlenmiştir. Tartışmalarda dikkat çeken diğer unsur ise mimari veri setleri olmuştur. Buna karşın, taşıyıcı sistem tasarımı aşamasında derin öğrenme kullanımı ile ilgili çalışmaların azlığı da dikkat çekmektedir. Bu nedenle bu çalışmanın motivasyonu literatüre önemli bir katkı sunacak olan derin öğrenme yöntemlerinin, ön tasarım aşamasında taşıyıcı sistem kararlarının doğru verilebilmesi için kullanmak üzerinedir. Çalışma ile mimarların bu sürecini (ön tasarım aşamasındaki taşıyıcı sistem kararlarını) kolaylaştıran bir sistemi oluşturmak hedeflenmiştir. Ülkemizde yapılan binalarda taşıyıcı sistem kararlarını verirken en önemli kaynaklardan biri Deprem Yönetmeliği'dir. Deprem Yönetmeliğinde belirtilen taşıyıcı sistem esaslarına göre tasarımda dikkat edilmesi gereken maddeler özetlenmiştir. Bunlardan biri de taşıyıcı sistem düzensizlikleridir. Bu çalışmada, yapay zekâ yöntemlerinden derin öğrenme ve görüntü sınıflama metodu kullanılarak, makineye düzenli ve düzensiz taşıyıcı sistemler öğretilmiştir. Bu öğrenme ile makineye bir plan yüklendiğinde, makinenin düzenli veya düzensiz bir taşıyıcı sisteminin mevcut olup olmadığına dair yorum yapabildiği gözlenmiştir. Tezin, bu açıdan mimarlık alanında yapay zekâ kullanımına katkı sağlayacağı düşünülmektedir. Düzensizlik Kontrol Asistanının kurgusunu oluşturabilmek için öncelikle deprem ve taşıyıcı sistem esasları ile planda ve düşeyde yaşanan düzensizliklerin ele alınması gerekmektedir. Bu nedenle ilk olarak aşağıdaki bölümlerde deprem ve taşıyıcı sistem esasları ve plan ve düşeyde yaşanan düzensizlikler anlatılmaktadır.

### **3.1. Deprem'in Yapılar Üzerindeki Etkisi**

Deprem, herhangi bir ön uyarı vermeden yer kabuğunun hareketi ile oluşan bir doğal afettir. Yerküre içinde ani enerji değişimlerinin oluşması, dünya yüzeyine titreşim dalgaları olarak ulaşması ve dağılması sonucu ile meydana gelir. Bu titreşimlere sismik dalga adı verilir. Sismik dalgalar enerjinin değiştiği noktadan dünyanın kütlesi içinde yayılarak yeryüzüne kadar gelir. Bu durum yeryüzünde harmonik titreşimler oluşturur. Ne zaman gerçekleşeceği tahmin edilemeyen



yeryüzünün bu sismik hareketleri, yapılara, insanların canına ve malına zarar vermektedir. Bu nedenden dolayı yapılar olabilecek deprem olasılıklarına ve senaryolarına göre özel olarak tasarlanmalıdır. Yapıları ayakta tutan, yapının taşıyıcı sistemleridir. Depreme dayanıklı yapı tasarımının en önemli kuralları yapı taşıyıcı sisteminin kurallara uygun düzenlenmesi, yeterli ve uygun malzemenin kullanılması ve deprem senaryolarına göre kurgulanması gerekliliğidir (Celeb, 2018, s. 3-4).

Zekai Celep, *Deprem Mühendisliğine Giriş: Depreme Dayanıklı Yapı Tasarımı* isimli kitabında depremin oluşumunu şu şekilde tanımlar:

*“Depremlerin çok büyük bir bölümü, yer kabuğunda soğuma ve çeşitli etkilerden meydana gelen şekil değiştirme enerjisinin ani olarak açığa çıkmasından meydana gelir. Böyle bir olay sırasında yer kabuğunu oluşturan plakalar kendisini sınırlayan çizgiler olan faylar (yer kabuğu kırıkları) boyunca ani olarak kırılır ve fay çizgisinde atım (görelî hareket) meydana gelir”* (Celeb, 2018, s. 3-4)

Tanımda da bahsedildiği üzere deprem yükleri dinamiktir ve diğer yüklerden farklı olarak yapı üzerine çarpma etkisi yaparlar. Zeminde oluşan ani deprem hareketleri tutarsızdır. Deprem hareketlerinin yapı üzerindeki etkisi taşıyıcı sisteme bağlı olarak değişmektedir (Celal & Kumbasar , 2004). Yapılar zemine bağlıdır ve bu nedenle deprem etkisi altındaki yapılar aniden büyük bir şiddet ile hareket etmeye başlarlar. Bu hareket karşısında yapının ataleti (durağanlığı) bu harekete direnç gösterir. Zemine sabit olan yapı deprem etkisi ile birlikte T periyodu adı verilen bir salınım hareketi başlatır (İdemen, 2003). Bu salınım karşı koyabilmek için yapıda kurgulanan taşıyıcı sistemin düzenli olması ve bu sayede düzensiz deprem kuvvetinde ortaya çıkabilecek zararların minimuma indirilmesi ve deprem güvenliğinin sağlanması gerekmektedir. Yapı güvenliğini doğru bir şekilde tanımlamak tecrübeye, rasyonel düşünceye ve karar verme ile ilgili deneyime doğrudan bağlıdır. Bunlarla birlikte yapının taşıyıcı sistemi depreme karşı düzenli ve uygun bir şekilde tasarlanırsa bile kimi durumlarda dolaylı olarak da etki görmektedir. Bu etki depremin oluşturduğu tsunamiler, toprak kaymaları, zeminin sıvılaşması gibi birçok faktörden biri olabilir. Bu nedenle depreme karşı güvenli tasarımda, yapının çevresel faktörleri de göz önünde bulundurulmalıdır (Ünay A. İ., 2002, s. 6-8).

### 3.2. Deprem ve Taşıyıcı Sistem Tasarım İlkeleri

Taşıyıcı sistem tasarımı her ne kadar inşaat mühendislerinin sorumluluk alanı gibi görünse de mimarların da erken tasarım aşamasında taşıyıcı sisteme dair aldıkları kararlar oldukça önemlidir. İnsanlara zarar verenin depremden çok depremden yıkılan binaların olduğu gerçeği düşünüldüğünde taşıyıcı sistem tasarımının mimarların ve mühendislerin ortak sorumluluğunda olduğu açıktır (Ünay A. İ., 2002). Mimarların tasarımının ilk evrelerinde aldığı temel kararlar olan çekirdek yerleşimi, planda ve kesitteki dolu ve boş alanlar, kütlelerin biçimlenişi, yapının rijitliğini ve güvenliğini önemli ölçüde etkiler. Mimarın, yapı güvenliğini riske atmayacak tasarımlar üretmesi için yapı ile ilgili esaslara ve yönetmeliklere uygun tasarımı ortaya koyması gerekmektedir. Deprem Yönetmeliği (2018) bina taşıyıcı sistemlerinin düzenlenmesinde dikkat edilecek üç ilke bahseder (Yönetmelik Bilgilendirme Eki 3A). Bu ilkeler;

- Taşıyıcı Sistemin Sadeliği ve Basitliği,
- Taşıyıcı Sistemin Düzenli ve Simetrik Olarak Düzenlenmesi,
- Taşıyıcı Sistemde Yeterli Dayanım ve Rijitlik'tir.

**Taşıyıcı Sistemin Sadeliği ve Basitliği:** Binanın deprem davranışının öngörülebilir ve hesaplanabilir olmasını sağlamak için taşıyıcı sistem kurgusunun olabildiğince sade ve yalın yapılması en önemli ilkedir (TBDY, 2018).

**Taşıyıcı Sistemin Düzenli ve Simetrik Olarak Düzenlenmesi:** Taşıyıcı sistemin planda düzenli ve simetrik olarak tasarlanması, döşemelerdeki yayılı kütlelerden kaynaklanan eylemsizlik kuvvetlerini en uygun biçimde düşey taşıyıcı sistem elemanlarına aktarmasıdır. Taşıyıcı sistemin simetrik düzenlenmesi ile kütle, rijitlik ve dayanım bakımından öngörülebilir bir deprem davranışı gerçekleştirilebilir. Taşıyıcı sistem düşey ekseninde de düzenli bir şekilde tasarlanmalıdır. Kat rijitliklerinde ve dayanımlarında oluşabilecek ani değişimler ile yumuşak kat ve zayıf kat durumundan kaçınılır (TBDY, 2018).

**Taşıyıcı Sistemde Yeterli Dayanım ve Rijitlik:** Deprem, planda bütün doğrultularda etkili olabileceği dikkate alınarak, taşıyıcı sistemin birbirine dik iki asal doğrultuda düzenlenmesi ve birbirine yakın dayanıma ve rijitliğe sahip olması gerekir. Burulma düzensizliğini ortadan kaldırmak ve önlem almak için yeterli burulma dayanımının ve rijitliğinin sağlanması şarttır (TBDY, 2018).

Bu ilkelere uymayan binalar düzensiz binalar olarak adlandırılır. Düzensiz binalar depreme karşı davranışlarındaki olumsuzluklar nedeni ile tasarımından ve yapımından kaçınılması gereken yapılardır. Kaçınılması gereken bu düzensiz durumlar deprem yönetmeliğinde “Planda Düzensizlik Durumları” ve “Düşeyde Düzensizlik Durumları” olmak üzere iki gruba ayrılmıştır (TBDY, 2018).

### **3.3. Düzensiz Binaların Tanımı**

Düzensiz binalar depreme karşı davranışlarındaki olumsuzluklar nedeni ile tasarımından ve yapımından kaçınılması gereken yapılardır. Düzensiz durumlar deprem yönetmeliğinde iki gruba ayrılmıştır. Bunlar:


- Planda Düzensizlik Durumları
- Düşeyde Düzensizlik Durumlarıdır (TBDY, 2018).

#### **3.3.1. Planda Düzensizlik Durumları**

Plan düzleminde yapının deprem davranışını etkileyen iki temel sorun rijitlik merkezinin yerinin değişmesi ve serbest salınım yapabilecek kadar uçların uzatılmasıdır. Bunlar Deprem Yönetmeliği’nde A grubu düzensizlikler olarak tanımlanmaktadır. A grubu düzensizlikleri de A1, A2 ve A3 tipi düzensizlikleri içermektedir. Bunlardan A1 ve A2 tipi düzensizlikleri oluşturan burulma düzensizliği (A1) ve döşeme süreksizliği (A2) düzensizlikleri, ağırlık merkezi ve geometrik merkezin üst üste düşmesini engelleyecek plan düzenlemeleri, yapının rijitlik merkezini değiştirdiği ve dayanımda ani azalmalara neden olduğu için yapıda düzensizlikler meydana getirmektedir.


Deprem Yönetmeliği'nde "burulma düzensizliği" olarak ifade edilen A1 tipi düzensizlik durumu:

"Birbirine dik iki deprem doğrultusunun herhangi biri için, herhangi bir katta en büyük görel kat ötelemesinin o katta aynı doğrultudaki ortalama görel ötelemeye oranını ifade eden Burulma Düzensizliği Katsayısı  $\eta_{bi}$  'nin 1.2'den büyük olması durumudur." (Şekil 16) (TBDY, 2018).




Şekil 16. Burulma Düzensizliği (Torsional Irregularity) (TBDY, 2018).

A2 tipi düzensizlik durumu ise "döşeme süreksizliği" olarak tanımlanır ve Deprem Yönetmeliği'ne göre; "Herhangi bir kattaki döşemede (Şekil 17); I–Merdiven ve asansör boşlukları dahil, boşluk alanları toplamının kat brüt alanının 1/3'ünden fazla olması durumu, II–Deprem yüklerinin düşey taşıyıcı sistem elemanlarına güvenle aktarılabilmesini güçleştiren yerel döşeme boşluklarının bulunması durumu, III–Döşemenin düzlem içi rijitlik ve dayanımında ani azalmaların olması" durumunda gerçekleşir (TBDY, 2018).



**Şekil 17: Döşeme Düzensizliği (Floor Discontinuity) (TBDY, 2018).**

A grubu düzensizliklerinin son tipi olan A3 tipi düzensizlikte ise plandaki çıkıntılarının uzaması ile yapının kollarının deprem anında kontrolsüz salınarak hasar oluşturması problemi oluşmaktadır. Deprem Yönetmeliği'nde A3 düzensizliği "Bina kat planlarında çıkıntı yapan kısımların birbirine dik iki doğrultudaki boyutlarının her ikisinin de, binanın o katının aynı doğrultulardaki toplam plan boyutlarının %20'sinden daha büyük olması durumu" olarak tanımlanmaktadır (Şekil 18) (TBDY, 2018).



*A3 türü düzensizlik durumu:*  
 $a_x > 0.2 L_x$  Ve aynı zamanda  $a_y > 0.2 L_y$

**Şekil 18 : Planda Çıkıntılar Bulunması (Projections in Plan) (TBDY, 2018)**

### 3.3.2. Düşeyde Düzensizlik Durumları


Deprem yönetmeliğinde ikinci grup olan “Düşey Doğrultudaki Düzensizlikler” dikkat edilmesi gereken diğer bir konudur. Deprem Yönetmeliği’ne göre aşağıdaki şekilde sınıflandırılmaktadır.

Bunlar (TBDY, 2018):

- Komşu Katlar Arası Dayanım Düzensizliği (Zayıf Kat),
- Komşu Katlar Arası Rijitlik Düzensizliği (Yumuşak Kat),
- Taşıyıcı Sistemin Düşey Elemanlarının Süreksizliği şeklindedir.


Bu düzensizlik durumlarından kaçınmalıdır.

**Komşu Katlar Arası Dayanım Düzensizliği (Zayıf Kat):** Betonarme binalarda, birbirine dik iki deprem doğrultusunun herhangi birinde, herhangi bir kattaki toplam etkili kesme alanının, bir üst kattaki toplam etkili kesme alanına oranı olarak tanımlanan Dayanım Düzensizliği Katsayısı  $\eta_{ci}$ ’nin 0.80’den küçük olması durumudur (Şekil 19) (TBDY, 2018).



Şekil 19: Düşeyde Düzensizlik Durumları

**Taşıyıcı Sistemin Düşey Elemanlarının Süreksizliği:** Taşıyıcı sistemin düşey elemanlarının (kolon veya perdelerin) bazı katlarda kirişlerin üstüne veya ucuna oturtulması, ya da üst kattaki taşıyıcının altta kolonlara oturtulması durumudur (Şekil 20) (TBDY, 2018).



**Şekil 20 Taşıyıcı Sistemin Düşey Elemanlarının Süreksizliği**

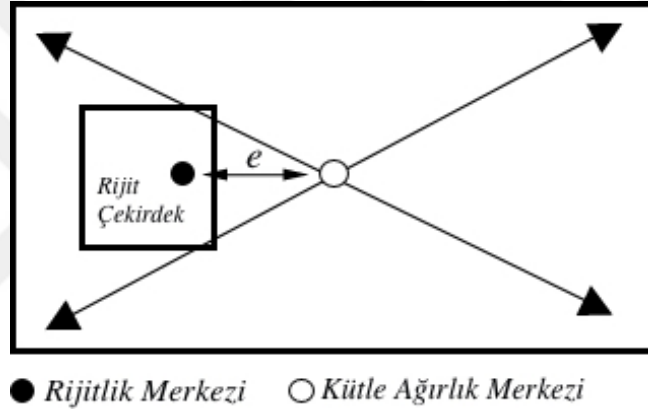
**Komşu Katlar Arası Rijitlik Düzensizliği(Yumuşak Kat):** Birbirine dik iki deprem doğrultusunun herhangi biri için, bodrum katlar dışında, herhangi bir i'inci kattaki ortalama görelî kat ötelemesi oranının bir üst veya bir alt kattaki ortalama görelî kat ötelemesi oranına bölünmesi ile tanımlanan Rijitlik Düzensizliği Katsayısı  $\eta_{ki}$  'nin 2.0'den fazla olması durumudur (TBDY, 2018).

### **3.4. Düzensiz Bina Tasarımının Deprem Davranışına Etkisi**

Yapıların simetrik olmayan yük dağılımları nedeni ile yapılar sürekli olarak bir burulma durumu içerisinde dir. Kolon ve perde gibi düşey taşıyıcı elemanların dağılımları plan üzerinde dengeli değilse burulma riski artmaktadır. Bina üzerindeki burulma düzensizliğini ortaya çıkartan durum, yapının üzerinde bulunan kütle merkezi ile rijitlik merkezinin ilişkisinden kaynaklanır. Kütle merkezi, yapının geometrik olarak merkezinde yer alır, öte yandan rijitlik merkezi kolon ve perde düşey taşıyıcı elemanların bulunduğu konuma göre değişiklik gösterir (İdemen, 2003).

### 3.4.1. Rijitlik Merkezi

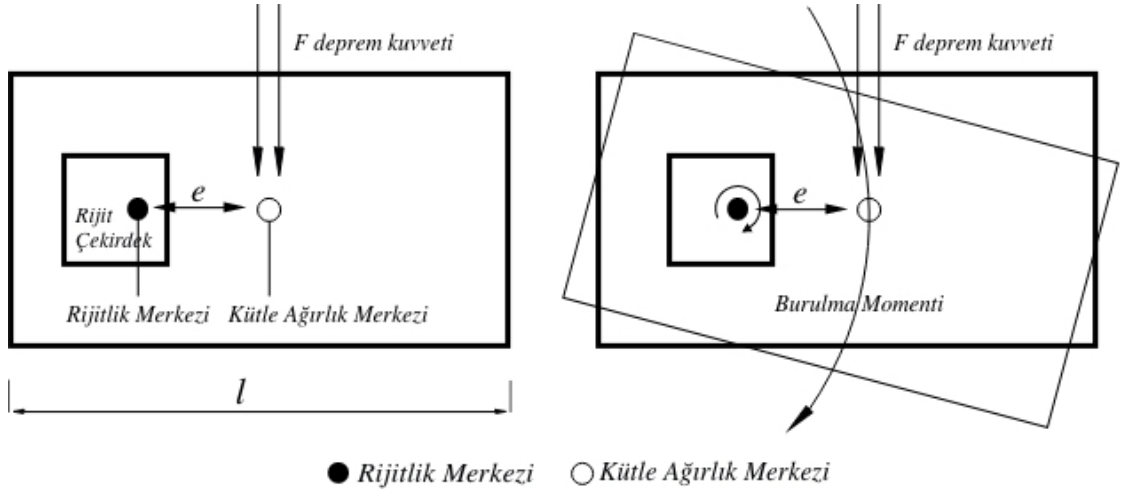
Yapının herhangi bir kat planında, plan düzleminde ki ağırlık merkezi, perde, kolon ve çekirdek arasındaki ilişki ile rijitlik merkezi elde edilir. Rijitlik merkezi, katta öteleme hareketi yapmadan, etrafında dönebileceği noktadır. Bu nokta, ayrıca düşey taşıyıcı elemanların ataletlerinin ağırlık merkezi olarak da tanımlanmaktadır. Ağırlık merkezi ise bir kat planına etkileyen bileşke yer çekimi kuvvetlerinin etkidiği noktadır. Basit anlamda bir dikdörtgenin köşegenlerinin kesiştiği nokta onun ağırlık merkezi olarak tanımlanabilir (Celep ve Kumbasar, 1993). Şekil 21’de görüldüğü üzere kütle ve rijitlik merkezleri tanımlanmıştır.



Şekil 21: Kütle ve Ağırlık Merkezi Şeması

Burulma momentini azaltmak için, yapının kütle ve ağırlık merkezlerinin birbirlerine yakın konumlandırılması veya üst üste çakıştırılması gerekir. Simetrik olmayan yapılarda genellikle kütle ve rijitlik merkezinin birbirlerinden farklı konumlarda yer almaktadır (Döndüren, ve d., 2007). Şekil 22’de görüldüğü üzere kütle ve rijitlik merkezleri tanımlanmıştır.





**Şekil 22: Dış Merkezlik ve Deprem Kuvveti Şeması**

**Dış merkezlik formülü:** Binanın dış merkezliği ( $e$ ) = rijitlik merkezi – ağırlık merkezi uzaklığı Olması gereken dış merkezlik ( $e_i$ ) =  $l/20$ .

Binanın herhangi bir kat planında, plan düzleminde ağırlık merkezi, perde ve kolonlar gibi düşey taşıyıcı sistem elemanlarından da rijitlik merkezi elde edilir. Bu iki merkeze ait noktalar arasındaki uzaklığa ( $e$ ) dış merkezliği denmektedir. Bu uzaklık Afet Bölgelerinde Yapılacak Yapılar Hakkında Yönetmelik'te tanımlandığı üzere, o kat planındaki en uzun kenarın  $1/20$  sini aşmamalıdır (Şekil 22). Bu değerin aşıldığı durumlarda aradaki mesafe kadar ek bir moment kolu oluşacağından o kat,  $F$  yatay kuvveti etkisinde bir dönme hareketi yapar ve bu yer değiştirme,  $F$ 'nin büyüklüğüne bağlı olup, binanın yıkılmasına kadar gidebilecek sonuçlar doğurabilir.

Bu çerçevede sonuç olarak, burulma düzensizliği probleminin önlenmesi için mimari tasarım aşamasında taşıyıcıların birbirine göre konumu ve aralıkları, boyutları, yapı çekirdeğinin konumu vb. durumların kontrol edilmesi gerekir. Taşıyıcı elemanların plan düzleminde bir bölgede yoğunlaşması ve sıklaşması yapıyı daha rijit hale getirmemekte, tam tersine yapısal dengeyi bozarak rijitlik merkezinin yerini değiştirmektedir. Bu nedenle tasarımın plan düzleminde, özellikle yapı çekirdeğinin konumuna göre, kolonlar ve perdelerin konumu dengelenecek şekilde, sade, düzenli ve eşit boyut ve aralıklı yapılması gerekir. Bu kurallar dışında tasarlanan taşıyıcı sistemler deprem yükleri altında sakıncalıdır.

Bu nedenle çalışmada, sorunların erken tasarım evresinde tespit edilebilecek ve uyarıda bulunarak ileride meydana gelebilecek sorunların önüne geçilmesini sağlayacak, görüntü sınıflandırma ve derin öğrenme yöntemi ile bir uygulama geliştirilmiştir. Düzensizlik Kontrol Asistanı (DK-Asistanı) olarak adlandırılan bu uygulamada, Şekil 22’de görülen dış merkezlik formülü göz önünde bulundurularak, planda düzensizlik durumlarından A1 tipi düzensizlik durumu barındıran plan şemaları, derin öğrenme ve görüntü sınıflandırma yöntemleri ile makineye öğretilmiştir.



## DÖRDÜNCÜ BÖLÜM

### KULLANILAN MATERYALLER

#### 4.1. Düzensizlik Kontrol Asistanının Kurgusu

Çalışma kapsamında geliştirilen DK-Asistanı derin öğrenme destekli bir bilgisayar uygulamasıdır. Mimari plan düzleminde taşıyıcı sistem şemasında herhangi bir düzensizlik olup olmadığını saptamayı hedefler. DK-Asistanı, bu işlemi Deprem Yönetmeliği'nde yer alan planda taşıyıcı sistem düzensizliklerinden, burulma düzensizliği esaslarına göre gerçekleştirir. Tasarlanan DK-Asistanı, düzenli ve düzensiz taşıyıcı sistemler olarak tanımlanmış mimari planları, makinaya öğretilmiş şemalara olan benzerliklerine göre değerlendirir.

DK-Asistanının analiz programlarından farkı, tasarımın erken aşamasında yapının taşıyıcı sisteminin düzenli mi yoksa düzensiz mi olduğuna dair bir erken uyarı sistemi gibi çalışmasıdır. Bu sayede deprem güvenliği ilk olarak erken tasarım evresinde başlamış olur. Uygulama daha sonradan ortaya çıkabilecek büyük revizyonların da önüne geçmeyi sağlamaktadır.

DK-Asistanı *PYTHON* script dilinde üretilmiştir. Veri seti modelleri ise derin öğrenme algoritmalarının ve mimarilerin hazır olarak bulunduğu *IMAGE AI* yapısı ile *Colab Notebook*'ta işlenmiştir. *Colab (Colaboratory) Notebook*, makine öğrenimi için araştırma ve geliştirmede kullanılan web tabanlı bir interaktif ortamıdır. Herhangi bir kurulum gerekmeden *Google Cloud* ile çalışarak kullanıcıya sanal bir ortam sağlamaktadır. Tez kapsamında modellerin eğitimi *Google Colab Notebooks* kullanılarak yapılmıştır.

*Image AI* ise kodlama yükünü hafifleten yöntemi ile imaj sınıflandırma işlemi yapılmasını sağlayan açık kaynaklı bir *PYTHON* kütüphanesidir.

#### 4.1.1. Kullanılan Materyaller

**PYTHON:** *PYTHON* açık kaynak bir *script* dilidir. 1991 yılında Guido van Rossum tarafından yaratılmıştır. Python' un tasarım felsefesi olabildiğince sade ve yazım diline benzer nesne yönelimli bir dil olmasıdır. Dil yapısı nedeni ile programcılarının veya akademik araştırmacılarının küçük ölçekli prototipler veya büyük ölçekli projeler için kolay, açık bir kodlama dili olmayı amaçlamıştır (Kuhlman, 2013).

*PYTHON* kütüphanelerini yönetmek için *PYTHON* ile birlikte gelen, *Python* için entegre geliştirme ortamı *IDLE* (*integrated development environment for Python*) kullanılmıştır. Derin öğrenme ile ilgili yapılan çalışmalar ve kullanılan paket ve programlar çoğunlukla *PYTHON* dilinde yapılmıştır (Python, 2020).

Bu tez kapsamında, derin öğrenme algoritması *ResNet*, Derin öğrenme modeli *OpenCV*, yapay sinir ağı kütüphanesi olarak *TensorFlow1.4* ve *Keras*, bilgisayarlı görme için *ImageAI* yapısı kullanılmıştır.

**TKinter:** Her ne kadar, *ImageAI* imaj sınıflandırma için her şeye hazırlasa da, kullanıcı tecrübesi bakımından bir ara yüze ihtiyaç vardır. Bu sebepten ötürü *TKinter* kullanılarak kullanıcı ara birimi kodlanmıştır. *Tkinter*, *Python* ortamı için sunulan bir arabirim kütüphanesidir. Tez kapsamında ortaya çıkartılan yazılım ürünü *DK-Asistanı Tkinter* kütüphanesi kullanılarak yazılmıştır. *TKinter* aynı zamanda *PYTHON*'ın standart ara yüz kütüphanesidir. Bu kütüphane, *Microsoft Windows* ve *Python*'ın *Mac OS X* kurulumlarına dahildir (Wiki Python, 2020).

**TensorFlow ve Keras:** *TensorFlow*, makine öğrenme algoritmalarını ifade etmek ve algoritmaları yürütmek için kullanılan bir uygulamadır. Sembolik bir matematik kütüphanesidir ve sinir ağları gibi makine öğrenimi uygulamaları için de kullanılır. *Google Brain* ekibi tarafından, *Google*'ın kullanımı için geliştirilmiş ve sonradan herkese açılmıştır (Martin Abadi, Agarwal, Barham, & vd, 2020).

*Keras* ise *PYTHON*'da yazılmış açık kaynaklı bir yapay sinir ağı kütüphanesidir. *TensorFlow*, *Microsoft Cognitive Toolkit* ve *Theano* yapılarının üzerinde çalışmaktadır. Derin sinir ağları ile hızlı deneyler yapabilmek için tasarlanmıştır. *Keras* kütüphanesi *PYTHON 2.7-3.6* arasında çalışmaktadır (Keras, 2020). Bu bileşenler *ImageAI* ile birlikte dolaylı olarak kullanılmıştır. *ImageAI* yapısını kullanabilmek için oluşturulan ortama bu iki bileşenin kurulması gerekmektedir.

**OpenCV:** Gerçek zamanlı bilgisayar görmeyi amaçlayan bir programlama fonksiyonları kütüphanesidir (Pulli ve Ark, 2012). Bu kütüphane hem klasik hem de son teknoloji bilgisayarlı görme ve makine öğrenme algoritmalarının kapsamlı bir setini içermektedir. 2500'den fazla optimize almaya sahiptir. Bu algoritmalar yüzleri algılamak ve tanımak, nesnelere tanımlamak, videolardaki insan eylemlerini sınıflandırmak, nesnelere 3B modellerini çıkarmak, yüksek çözünürlük üretmek ve görüntüleri birleştirmek için kullanılmaktadır (OpenCV, 2020). OpenCV-Python ise bilgisayarlı görme sorunlarını çözmek için tasarlanmış bir *Python* bağlantı kütüphanesidir (DocsOpenCV, 2020).

**ImageAI:** Tez kapsamında yeni modeller eğitmek ve eğitilen modellere göre sınanacak olan grafikleri analiz etmek için kullanılmıştır.

ImageAI, araştırmacılar, öğrenciler ve geliştiriciler için basit ve az sayıda kod satırı kullanarak hızlı ve etkili prototip veya ürün ortaya çıkartmalarını sağlayan bir Python kütüphanesidir. Bu kütüphane, Moses Olafenwa ve *DeepQuest AI* ekibinden John Olafenwa tarafından geliştirilmiş bir derin öğrenme ve bilgisayarlı görme projesidir (Olafenwa, 2019). *ImageAI*, *PYTHON 3.5.1* veya daha güncel bir versiyon ile çalışır. Yukarıda bahsedilen, *TensorFlow1.4*, *OpenCV* ve *Keras* 'i otomatik olarak çalıştırdığından programın yapıldığı ortama önceden Python paket yöneticisi ile birlikte (PyPi) yüklenmesi gerekmektedir (Olafenwa, 2019).


ImageAI, yapay zeka başlığı altında tanıtılan derin öğrenme algoritmalarını içinde barındırmaktadır (*SqueezeNet*, *ResNet*, *InceptionV3*, *DenseNet*). Bu nedenle araştırmacı, daha az kodlama ve optimizasyon işlemi yapar. Aynı zamanda ImageAI araştırmacıların kendi veri setlerini oluşturarak çok hızlı bir şekilde kendi modellerini oluşturabilmelerini de sağlamaktadır (Olafenwa, 2019).

Burada dikkat edilmesi gereken eğitilecek modelin en az 2 farklı sınıftan oluşan bir veri setine sahip olması gerektiğidir. Kedi/köpek veya düzenli/düzensiz gibi iki sınıf oluşturulabileceği gibi, aslan/ kaplan/ev kedisi/leopard gibi ikiden fazla sınıf da oluşturulabilir. Maksimum tutarlılığı almak için veri setlerinin her bir sınıf için en az 500 adet olması gerekmektedir (Olafenwa, 2019). Tez kapsamında daha hızlı ve etkili prototip çıkartmak ve modelleri eğitmek için bu kütüphaneden yararlanılmıştır.

## 4.2. Veri Setleri

Veri setleri, planda düzensizlik durumları başlığı altında yer alan “A1 Tipi Düzensizlik: Burulma Düzensizliği” içeren ve içermeyen şemalardan oluşmaktadır. Veri setleri toplam, 2 plan tipi, 3 kolon tipi ve 6 farklı model kombinasyonundan oluşmaktadır. Her bir model kombinasyonu kendi içinde, yönetmelikte yer alan rijitlik ve ağırlık merkezinin tanımları ve formüllerine göre düzenli ve düzensiz olarak sınıflandırılmıştır. Veri setleri betonarme kolon, perde ve düşey sirkülasyon elemanları düzenini gösteren ve rijitlik merkezleri birbirinden farklı olan şemalardır. Tez kapsamında bu modeller sınanarak verdikleri sonuçlar karşılaştırılmıştır. Derin öğrenme için kullanılacak verilerin doğru sınıflandırılması gerekmektedir. Çalışmada dış merkezlik formülü göz önünde bulundurularak veri setleri oluşturulmuş ve düzenli/düzensiz olarak sınıflandırılmıştır.


Bugüne kadar araştırmacılar derin öğrenme ve bilgisayarla görme konusunda, görüntü üzerinden hastalıkların tespiti, trafik işaretlerinin okunması, el işaretlerinin okunması ve insan yüzünden yaş ve cinsiyet tespiti gibi konuları araştırmış ve ürünler ortaya çıkartmıştır. Bu referanslar ışığında bu çalışmada da Şekil 23’teki gibi makinaya bir plan şeması gösterilerek düzensizlik yorumu yapabilmesi hedeflenmiştir. Modeller yalın ve sade plan şemaları ile plan ölçeğine yakın karma şemalardan oluşturulmuştur.



Şekil 23: Düzensiz Plan ve Düzensiz Şeması

#### 4.2.1. Veri Setlerinin Hiyerarşisi

İleri çalışmalarda daha fazla model oluşturabilmek için modüler bir kategorizasyon yapılmıştır. Bu sayede sınanmak istenen hipoteze göre yeni modeller oluşturulabilir. Şekil 24’de görüldüğü üzere, veri setleri önce kolon tiplerine göre sınıflandırılmış daha sonrasında kolon tiplerine göre plan tipleri olarak alt sınıflara ayrılmıştır. Plan tiplerinin artması sonuçlardaki doğruluk oranının da artmasına sebep olacağı için çok sayıda model oluşturulmaya çalışılmıştır.



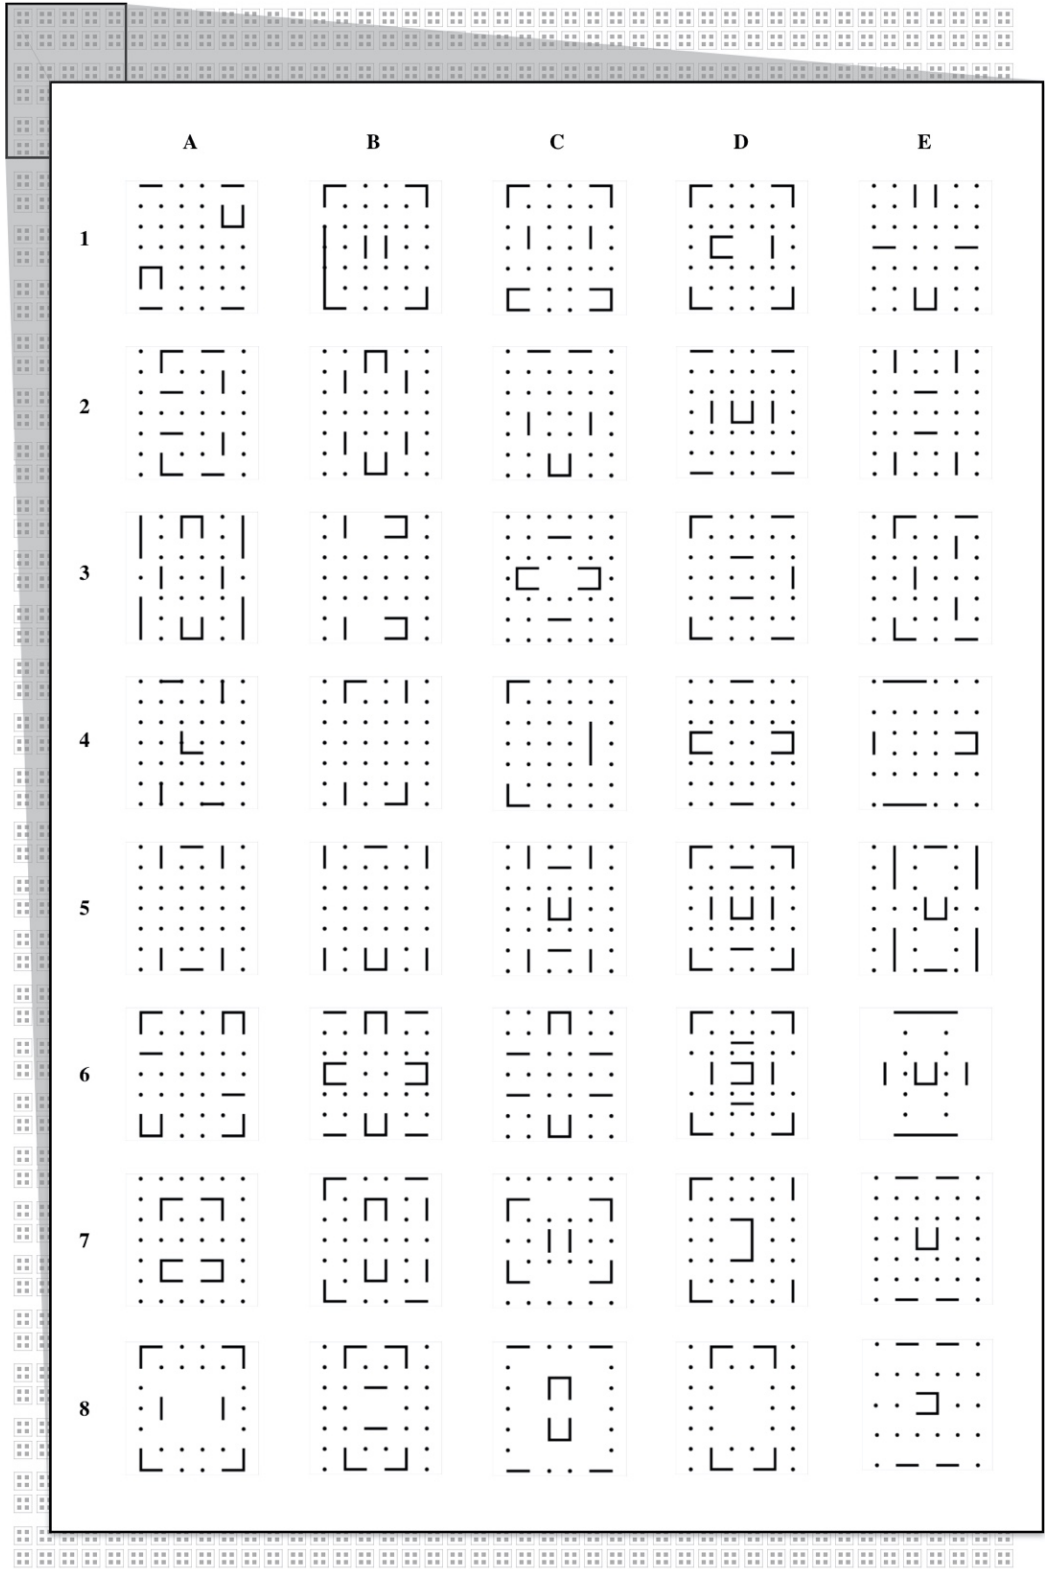
Şekil 24: Veri Setinin Dosya Hiyerarşisi

Tablo 1’de ise her bir hiyerarşideki şema tipleri verilmiştir. Toplamda birbirinden farklı 1344 adet orijinal şema bulunmaktadır. Bu şemaların sayısı görüntü çoğullama işleminden sonra 21504 adete yükselmiştir. Düzenli ve düzensiz olarak sınıflandırılan veri setleri Şekil 25 ve Şekil 26’da gösterilmiştir.


**Tablo 1: Veri Setlerinden Örneklem**

|   | A | B | C | D | E |
|---|---|---|---|---|---|
| 1 |   |   |   |   |   |
| 2 |   |   |   |   |   |
| 3 |   |   |   |   |   |
| 4 |   |   |   |   |   |





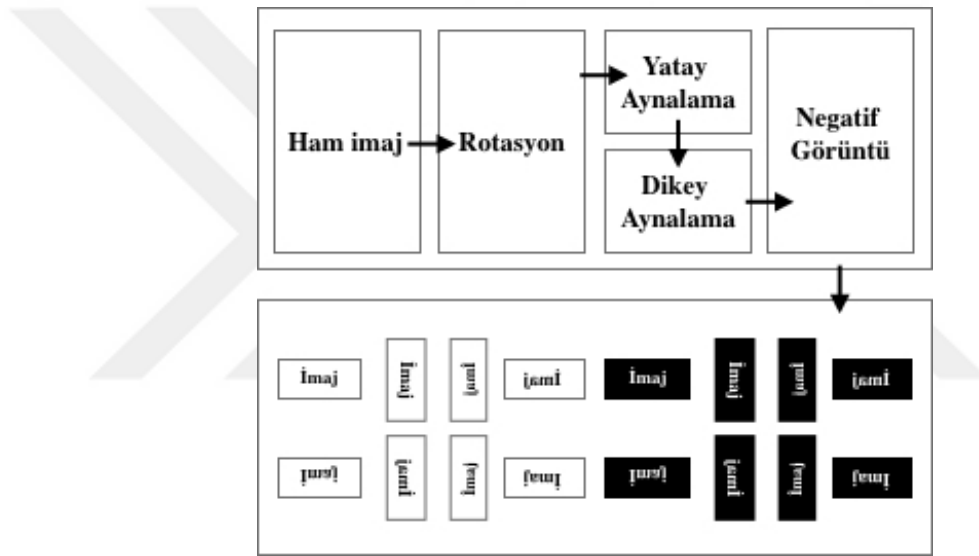
Şekil 25: Düzenli Veri Seti Sınıfı Örnekleme



Şekil 26: Düzensiz Veri Seti Sınıfı Örneklemi


#### 4.2.2. Görüntü Çoğaltma

Veri setlerinde bulunan şemaların sayısını artırmak ve daha tutarlı sonuçlar elde edebilmek için veriler çoğaltılmıştır. Derin sinir ağları, *batch* eğitimini desteklemektedir. Bu nedenle oluşturulan veri setlerine, öğretilen plan şemalarının çoklu yapay sinir ağı katmanları için çoğullama işlemi yapılmıştır. Bu çoğullama işlemi veri setinin az olduğu durumlarda modelin başarı ihtimalini güçlü bir biçimde artırır (Perez ve diğerleri, 2017). Önce ham imaj referans alınarak, rotasyon, yatay ve dikey ekseninde aynalama yapılmış ve negatifleri alınarak makinenin pikseller arasındaki farkları anlaması sağlanmıştır. Bu işlem her bir model için ayrı ayrı yapılmıştır.




Şekil 27: Görüntü Çoğullama Akış Diagramı

Şekil 27’de imaj çoğullama akış diagramı bulunmaktadır. Bu diagram, yapılan çalışmanın konusuna ve kurgusuna göre değişiklikler göstermektedir. Diyagramda, imaj dört farklı işlemde geçmektedir. Her bir işlem, bir önceki işlemin toplam planı üzerinden gerçekleştirilir. İlk aşamada imaj 90 derecelik rotasyon işleminden geçer. Bu işlemden sonra toplam iki plan bulunmaktadır. Yatay aynalama ile plan sayısı 4’e, dikey aynalama ile de plan sayısı 8’e çıkar. Son olarak imajların negatifleri alınır ve toplamda 16 adet imaj elde edilmiş olur. Şekil 28’de örnek olarak bir şemanın görüntü çoğullama sonrasındaki durumu görülmektedir.



**Şekil 28: İmaj Çoğullama İşlemi**




**Grafik 1: Ham ve Artırılmış Setin Farkı**

Tez kapsamında toplamda 1344 şema örneği bulunmaktadır (Grafik 1). Çoğullama metodu ile elde edilen güncel veri seti ise 21504 olmuştur.

### 4.2.3. Modeller


Veri setleri oluşturulurken gerçek mimari planlar yerine, üretilen taşıyıcı sistem şemaları kullanılmıştır. Bu şemalar daha önce ifade edilen problemin derin öğrenme yöntemi ile tutarlılığını ölçmek için kullanılmıştır. Ayrıca, veri setlerini hazırlamak için gerçek mimari planları elde etmek ve sınıflamak zaman alan maliyetli bir işlemdir. Bu nedenle gerçek mimari plan yerine planlara benzeyen şemalardan oluşan modeller tasarlanmıştır. Bu sayede daha etkili ve ekonomik bir çözüm önerisi sunmak hedeflenmiştir. Bu kapsamda toplamda altı adet veri seti (M1,M2, M3, M4, M5, M6) üretilmiştir. Aşağıda kısaca bu veri modelleri özellikleri bakımından incelenmektedir.

**M1 ve M2 Veri Modelleri:** (Şekil 29) Bu şemanın özelliği kare tip kolon ve 6x4 aks planlardan oluşmasıdır. Bu plan grubundaki toplam veri sayısı 2512'dir. %20 oranında "test" %80 oranında "train" verisi içermektedir. Sınıflandırma %40 düzensiz %60 düzenli şekilde oluşturulmuştur.




Şekil 29: M1 ve M2 Veri Setinin Örneklemi

**M3 ve M4 Veri Modelleri:** (Şekil 30) Oranları M1 ve M2 ile aynı olmasına rağmen, kolon tipleri bakımından farklılaşmaktadır. Kare kolondan oluşan bu veri setine oval, dikdörtgen kolon tipleri eklenerek yeni şemalar üretilmiştir. Toplam veri sayısı 6992'dir.




Şekil 30: M3 ve M4 Veri Setinin Örneklemi

**M5 Veri Modeli:** (Şekil 31) M5 tipi ise 7x6 ve 6x4 aks plan tiplerini bir arada barındırmaktadır. Diğer modellerden farklı olarak hem kolon tiplerinin hem de plan tiplerinin karması olarak kurgulanmıştır. Oranları diğer veri setleri ile aynıdır. Bu veri seti toplam 6997 şemadan oluşmaktadır.



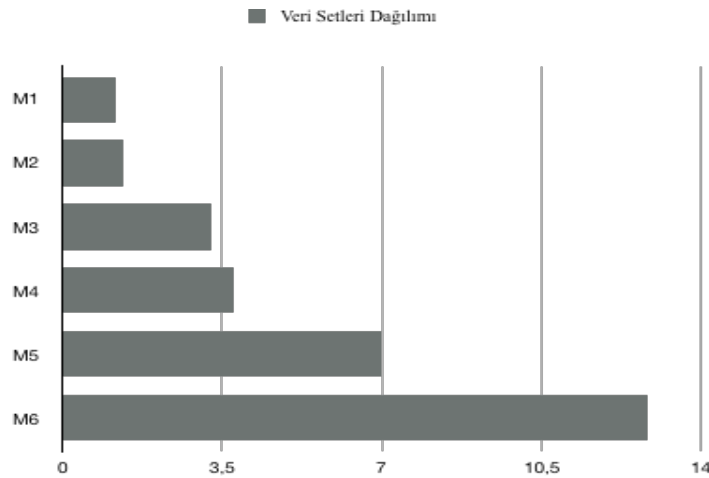
Şekil 31: M5 Veri Setinin Örneklemi

**M6 Veri Modeli:** (Şekil 32) M6 modeli M5 modeline ek olarak ölçekli ve gerçeğe daha yakın plan şemalarından oluşturulmuştur. Bu plan şemasında dengeler diğer veri setleri ile aynıdır. Bu veri setinde toplam 12,815 şema bulunmaktadır.



Şekil 32: M6 Veri Setinin Örneklemi

Grafik 2’ de bu veri setlerinin sayısal dağılımı gösterilmektedir. 1 birim 1000 adet şemayı temsil eder.



Grafik 2: Veri Setleri Sayısı

#### 4.2.4. Model Eğitimi

Görüntü sınıflandırma işlemini gerçekleştirmek için *ImageAI*'in sunduğu hazır altyapı kullanılmıştır. Bu alt yapı ResNet algoritması ve modeli üzerine kurulmuştur. Model eğitimi batch mantığı ile çalıştığından yüksek bir işlemci gücü gerektirmektedir.

*Bacth*, bilgisayarda toplu matematik problemlerinin, “son kullanıcı etkileşimi olmadan çalışabilen veya kaynakların izin verdiği şekilde çalışmak üzere zamanlanabilen” çalıştırılmasıdır (IBM, 2020). *Bacth*, yoğun işlemci gücü gerektirdiği için bu çalışmada, *Google* tarafından akademik çalışmalar için sunulan ve makine öğrenimi için kullanılan *Colab Notebook* tercih edilmiştir. Modelin eğitimi için fazladan GPU sağlamaktadır. Bu şekilde modellerin eğitimi daha kısa sürede tamamlanabilmektedir.

Model eğitiminde *ImageAI* yapısı altında iki farklı klasör yapısı bulunmaktadır. Bunlar eğitim (train) ve sınama (test) klasörleridir. Bu klasörlerin içerisinde veri setleri sınıflandırılmıştır. Test klasörü, modelin doğru eğitilip eğitilmediğini sınamaktadır. Bu klasöre koyulan plan şemaları train klasöründe bulunamazlar. Test ve train setinin ağırlıkları sırasıyla %20'ye %80 oranındadır.

Şekil 33'te de örnek veri modelinin eğitim öncesi klasör hiyerarşisi verilmiştir. Hiyerarşide düzenli ve düzensiz olarak iki sınıf olduğu görülmektedir. Bu sınıflardaki veri sayısı birbirine eşit değildir. Düzensiz plan şemalarının sayısı daha fazla tutulmuştur. Bunun sebebi makinanın düzensiz bir plan şemasını düzenli olarak algılaması riskidir. Modellerin düzenli ve düzensizlik ağırlıkları %40 düzenli; %60 düzensiz şeklinde kurgulanmıştır.

#### ÖRNEK DOSYA HİYERARŞİSİ



Şekil 33: Eğitim Öncesi Örnek Dosya Hiyerarşisi

ImageAI birçok parametreyi hazır sunduğu için fazladan bir işlem yapılmamıştır. Model eğitiminde kullanılan parametreler:

*Num\_objects 2;enhance\_data; batch\_size, model\_trainer.setModelTypeAsResNet* şeklindedir.

- **Num\_Objects=2:** Kaç farklı sınıfın kullanıldığını ifade etmektedir. Çalışmada düzenli ve düzensiz olarak toplam iki farklı sınıf tanımlanmıştır. Bu nedenle Num\_objects 2 dir (ImageAI, 2020).

- **Num\_Experiments=100:** Algoritmanın veri seti üzerinde kaç kez eğitileceğini ifade etmektedir. Eğitim sayısı arttıkça eğitimin doğruluğu da artar (Olafenwa, 2019).

- **Enhance\_Data=True:** Bu parametre, eğitim için daha fazla örnek oluşturmak amacıyla veri setini otomatik olarak çoğaltır. Varsayılan olarak, yanlış (*False*) ayarlanmıştır. Ancak, veri setinde sınıf başına 1000'den az resim olduğu durumlarda doğru (*True*) olarak kullanılmıştır (Olafenwa, 2019).

- **Batch\_Size=32:** Eğitim sırasında algoritma, paralel olarak bir dizi görüntü üzerinde eğitilir. Bu nedenle, varsayılan değer 32 olarak gelmektedir. Bu çalışma kapsamında da gelen değer aynen korunmuştur (Olafenwa, 2019).

- **Model\_Trainer.SetModelTypeAsResnet():** ResNet algoritmasının oluşturulan veri seti üzerinde eğitilmiştir. Bu sınıf ResNet, InceptionV3, DenseNet gibi model türünün ayarlandığı alandır (Olafenwa, 2019).

Tablo 2’de modellerin eğitim parametreleri verilmiştir. Bu parametreler doğrultusunda modeller eğitilmiştir. Uygulama içerisinde kullanılmak üzere parametreler değiştirilerek yeni modeller de eğitilebilir. Uygulamanın tasarımı esnek olduğundan, modeller uygulama içerisinde gömülü değildir. Uygulamanın arabirimi ve çalışma prensibi bir sonraki başlıkta açıklanmaktadır.

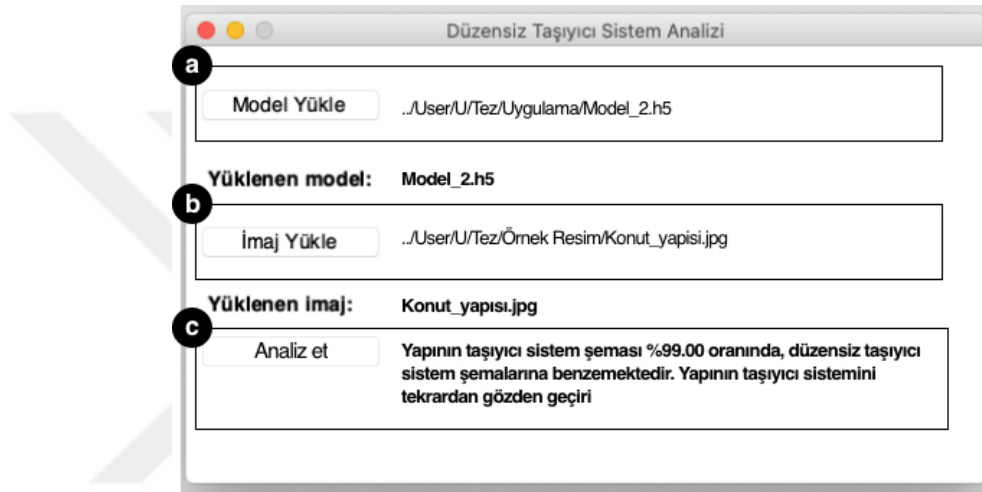
**Tablo 2: Model Eğitim Parametreleri**

| Modeller   | <i>Num_objects</i> | <i>Num_experiments</i> | <i>enhance_data</i> | <i>batch_size</i> |
|------------|--------------------|------------------------|---------------------|-------------------|
| M1,M2      | 2                  | 200                    | true                | 32                |
| M3, M4, M5 | 2                  | 100                    | true                | 32                |
| M6         | 2                  | 100                    | false               | 32                |



#### 4.2.5. DK-Asistanı Uygulamasının Kullanıcı Arabirimi

Kurgu olarak, daha sonradan başka eğitilmiş modeller ile kullanılabilmesi adına esnek ve modüler olarak tasarlanmıştır. Bu nedenle modeller uygulamanın içerisine gömülü olarak gelmemektedir. Daha sonra kullanacak olan kişinin kendi modellerini kullanabilmesi için, model ve sınanacak görüntüler uygulamanın kullanıcı arabirimi sayesinde seçilebilmektedir. Şekil 34’te DK-Asistanının ara yüzü görülmektedir. Bu ara yüz 3 bölümden oluşmaktadır: a, modelin yüklendiği alan; b, imajın seçildiği alan ve c, analiz sonucunun basıldığı alandır.



Şekil 34: DK-Asistanı Arayüzü

- Daha önceden eğitilen “*modelAdi.h5*” uzantılı bir dosyanın yüklendiği alandır. Bu model uygulamanın tahminleme fonksiyonu için gerekmektedir. h5 uzantılı model yüklenmediği sürece uygulama doğru çalışmayacaktır.
- İmaj yükle bölümünde sınamak istenilen mimari planın resmi yüklenir. Burada yüklenen imajın dosya uzantısı *.jpg* olmalıdır. PNG veya diğer grafik sıkıştırma biçimleri ile düzgün çalışmamaktadır.
- İmaj yüklendikten sonra c bölümü aktif olur. “Analiz et” butonuna basıldıktan sonra, uygulama kendi içerisinde önce modeli alıp daha sonra modele göre yüklenen resmi karşılaştırır. Son aşamada, ekrana önceden hazırlanmış ve çıkan değere göre gösterilen bir mesaj gelmektedir.

Araştırma kapsamında uygulamanın kullanıcı ara biriminin oluşturulması, ortaya somut bir ürün çıkartılabilmesi ve mimarlar tarafından kolaylıkla kullanılabilmesi için düşünülmüştür.

## BEŞİNCİ BÖLÜM

### DÜZENSİZLİK KONTROL ASİSTANININ UYGULANMASI VE DOĞRULANMASI

Tez kapsamında toplam 8 adet plan DK-Asistanı ile test edilmiştir. DK-Asistanının doğru sonuç verip vermediğini kontrol edebilmek için *Prota-Structure* yazılımı ile test edilen planların rijitlik merkezleri hesaplanarak deprem yönetmeliğinde verilen dış merkezlik formülüne göre kontrolleri yapılmıştır. DK-Asistanının verdiği sonuçlar ile *Prota-Structure* yazılımı sonuçları birbirleri ile tutarlı elde edilmiştir.


*Prota-Structure* deprem yönetmeliğine göre yapı taşıyıcı sistem analizi yapan bir yazılımdır. *Prota-Structure*, yapı sistemlerinin modellenmesi, sonlu elemanların analizi, yönetmelik destekli tasarımı, performans değerlendirmesi ve güçlendirilmesi için özel olarak geliştirilmiş kapsamlı bir yazılımdır (Prota, 2020).

DK-Asistanı ile test edilen ve *Prota-Structure* ile sonuçları doğrulanan çalışmada kullanılan plan örnekleri ve sonuçları aşağıda listelenmiştir.


#### 5.1. DK-Asistanı ve Prota-Structure ile Test Edilen Şemalar

Plan örnekleri gerçek mimari projelerden uyarlanmıştır.. Bu projelerin taşıyıcı sistem şemaları *Prota-Structure* yazılımında modellenmiş ve incelenmiştir. Şekil 35'te plan tipleri ve çeşitleri gösterilmektedir. Toplamda 5 adet düzensiz 3 adet düzenli plan kullanılmıştır. Düzensiz planlar rijitlik ve ağırlık merkezleri birbirinden farklı olan planlardır. Düzenli planlar ise yapı uzunluğunun 1/20 oranını geçmeyen rijitlik ve ağırlık merkezi farkına sahiptir.


Her bir plan birbirlerinden farklı birtakım özellikler barındırmaktadır. Plan 5x4 Düzenli Plan, Düzensiz Plan ve Dikdörtgen Plan şemasına sahiptir. 5x4 Düzensiz Planda rijitlik merkezi ile ağırlık merkezlerinin konumları birbirlerinden farklıdır. 5x4 düzenli planda ise rijitlik ve ağırlık merkezleri birbirlerine yakındır. Bu yakınlık deprem yönetmeliğinde ifade edilen sınırın içerisinde yer almaktadır.




**5x4 Dikdörtgen Düzensiz Plan**




**5x4 Dikdörtgen Düzenli Plan**




**10x4 Dikdörtgen Düzensiz Plan**




**10x4 Dikdörtgen Düzenli Plan**




**9x6 Elips Düzenli Plan**



**9x6 Elips Düzensiz Plan**



**3x3 Kare Düzensiz Plan**



**7x4 Kare Düzensiz Plan**

**Şekil 35: Test Planları**

Diğer iki örnek ise 10x4 Dikdörtgen Düzenli ve 10x4 Dikdörtgen Düzensiz plandır. Bunlar uzun iki elemanın ortak bir çekirdek ile birleşmesinden oluşmaktadır. Düzensiz plandaki çekirdek yerleşimi rijitlik merkezini değiştirecek şekilde bir aks kadar dışarıya kaydırılmıştır. Yapay zeka modeline öğretilen plan şemalarında çekirdekler dış merkezlere yakın konumlandırılmıştır. Bu planda ise rijitlik ve ağırlık merkezlerinin konumu birbirlerinden farklı, fakat çekirdek merkeze yakındır. Düzenli planda ise çekirdek yerleşimi merkezde bulunmaktadır.

9x6 Elips Düzenli Plan ve 9x6 Elips Düzensiz Plan ise, yapay zeka modeline öğretilen plan şemalarından tamamen farklıdır. Çekirdekler planın uzun kenarlarına simetrik olarak konumlandırılmıştır. 9x6 elips düzensiz plan incelendiğinde yapıda bulunan çekirdeklerden bir tanesi kasıtlı olarak silinmiş fakat kenar bölgelerdeki perde taşıyıcı elemanlar korunmuştur. Bu örneklerin modele öğretilen şemalardan farklı olması hedeflenmiştir.

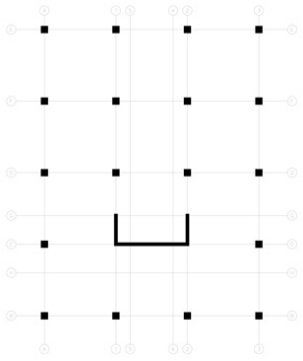

3x3 kare Düzensiz Plan ve 7x4 Kare Düzensiz Planda yapının ağırlık ve rijitlik merkezleri, perde duvar, çekirdek tasarımı ve konumu açısından birbirinden farklılaşmıştır. Bu fark 3x3 Kare Düzensiz Planda çekirdeğin konumu olurken 7x4 Kare Düzensiz planda ise perde duvarın tek bir bölgede oluşan yoğunluğudur. Sınırları belli olan elemanların makine tarafından okunması nispeten diğer uzun ve sınırları belli olmayan elemanlara göre daha kolaydır.

Oluşturulan 6 farklı yapay zeka modeli, planlar ile birlikte karşılaştırmalı olarak incelenmiştir. Bu inceleme sayesinde eğitilen modellerin plan tiplerinin farklı sonuçlar verdiği ortaya çıkmıştır.

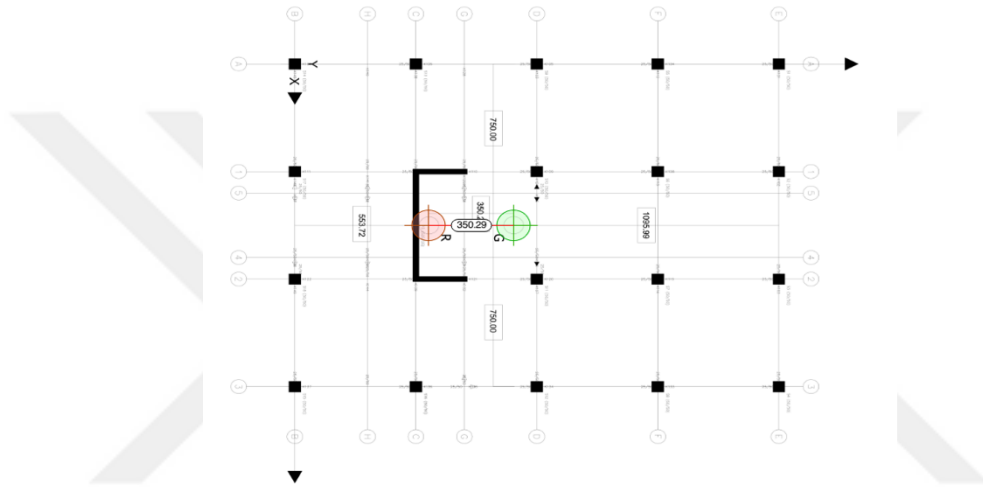
### 5.1.1. 5x4 Dikdörtgen Düzensiz Plan Şeması

Önceki bölümlerde bahsedilen teknik yöntemlere göre DK-Asistanı ile 5x4 Dikdörtgen Plan Şemasının, burulma düzensizliğine sahip olup olmadığı incelenmiştir. Bu inceleme sonucunda Tablo 3'te görüldüğü üzere DK-Asistanında test edilen plan %99,9 oranında düzensiz taşıyıcı sistem şemalarına benzer çıkmıştır. DK-Asistanı için oluşturulmuş M5, M4, M3, M2 ve M1 modellerinin analiz sonuçları incelendiğinde plan şeması bu modeller özelinde de sonucu %99,9 oranında düzensiz şemalara benzetmiştir.

**Tablo 3: 5x4 Dikdörtgen Düzensiz Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması  |       | DK-Asistanı   |       |       |       |       |
|--|-------|---|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller   | M6    | M5  | M4    | M3    | M2    | M1    |
| Düzenli  | %0.0  | %1.0  | %0    | %0    | %4.0  | %1.1  |
| Düzensiz   | %99.9 | %99.9   | %99.9 | %99.9 | %99.9 | %99.9 |

**Prota-Structure Yazılımına Göre:** Şekil 36’da görüldüğü üzere *Prota-Structure* yazılımı, plan şeması üzerinde ağırlık ve rijitlik merkezlerinin farkını hesaplayarak işaretlenmiştir. Bu fark incelendiğinde ağırlık ve rijitlik merkezleri farkı 350,35 olduğu görülmektedir. Tablo 4’ teki sonuçlar incelendiğinde ise x eksenindeki rijitlik merkezinin, yönetmelikte belirtilen sınırların içinde yer alırken, y eksenindeki rijitlik merkezinin ağırlık merkezine göre 350,35cm kayarak, toplam y eksen uzunluğunun 1/20’sini geçtiği saptanmıştır. Bu durumda yapıda rijitlik merkezinin konumundan ötürü burulma riski mevcuttur.



**Şekil 36: 5x4 Dikdörtgen Düzensiz Planın Prota-Structure Göre Rijitlik ve Ağırlık Merkezlerinin Farkı**

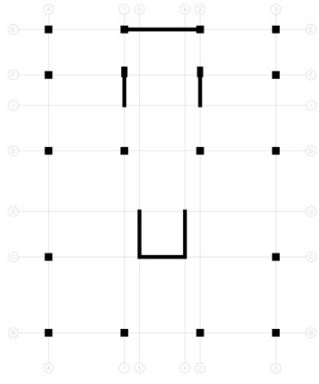

**Tablo 4: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları**

| Kat Genişliği B(y)   | Kat Genişliği- B(x) | Kat ağırlık merkezi- X(g) | Kat ağırlık merkezi-Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|--|---------------------|---------------------------|--------------------------|---------------------------|---------------------------|
| 2000.00  | 1500.00             | 750.00                    | 904.07                   | 750                       | 553.72                    |
| <b>Dış Merkezlik Formülüne göre koordinatların sonuçları</b>   |                     |                           |                          |                           |                           |
| 1/20 B(y)  | 1/20 B(x)           | X(g-r)                    | Y(g-r)                   | X(g-r)<1/20(x)            | Y(g-r)<1/20(y)            |
| 100  | 75                  | 0                         | 350,35                   | X(g-r) < 75               | Y(g-r) < 100              |
| <b>Sonuç: Düzensizdir.</b>   |                     |                           |                          |                           |                           |
| $B(y) = 2000.00\text{cm}$ , $1/20 B(y) = 100\text{cm}$ , $y(G-R) = 350,35\text{cm}$ 'dir. $350,35\text{cm} > 100\text{cm}$ |                     |                           |                          |                           |                           |


### 5.1.2. 5x4 Dikdörtgen Düzenli Plan Şeması

Diğer bir örnek ise 5x4 Dikdörtgen Düzenli Plan Şemasıdır. Bu şema DK-Asistanının sonucuna göre %95,6 oranında düzenli sistem şemalarına benzer çıkmıştır. Tablo 5’te yer alan sonuçlar incelendiğinde, DK-Asistanı bu modellerin (M6, M5, M4, M3) plan şemasını ortalama %90 oranında düzenli taşıyıcı sistem şemalarına benzetirken, M2 ve M1 %99 oranda modellerinin plan şemalarını düzensiz olarak sınıflamıştır. Bu sonuçlar incelendiğinde veri çeşidinin ve sayısının artışına bağlı olarak modellerin verdiği sonuçların daha tutarlı olduğu söylenebilmektedir.

**Tablo 5: 5x4 Dikdörtgen Düzenli Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması  |       | DK-Asistanı   |       |       |       |       |
|--|-------|---|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller   | M6    | M5  | M4    | M3    | M2    | M1    |
| Düzenli  | %95.6 | %90.8   | %87.7 | %94.4 | %0.3  | %0.5  |
| Düzensiz   | %4.3  | %9.1  | %12.2 | %5.5  | %99.6 | %99.4 |

**Prota-Structure Yazılımına Göre: 5x4 Dikdörtgen Düzenli Plan Şeması** *Prota-Structure* yazılımında incelendiğinde ise rijitlik ve ağırlık merkezlerinin farklı noktalarda olduğu fakat birbirine çok yakın konumlandığı Şekil 37’de görülmektedir. Tablo 6’da görülen *Prota-Structure* yazılımdan elde edilen sayısal değerlere göre dış merkezlik formülü uygulanmıştır. Elde edilen değerler incelendiğinde rijitlik ve ağırlık merkezlerinin farkı uzun kenara göre 86,78cm olarak tespit edilmiştir. Bu fark yapının uzun kenarının 1/20’sinden az olduğu için, yapıdaki burulma riski deprem yönetmeliğine göre bulunmamaktadır.



**Şekil 37: 5x4 Dikdörtgen Düzenli Planın Prota-Structure’ına Göre Rijitlik ve Ağırlık Merkezlerinin Farkı**

**Tablo 6: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları**

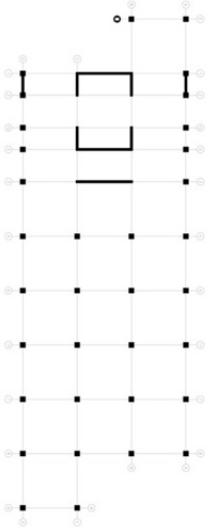
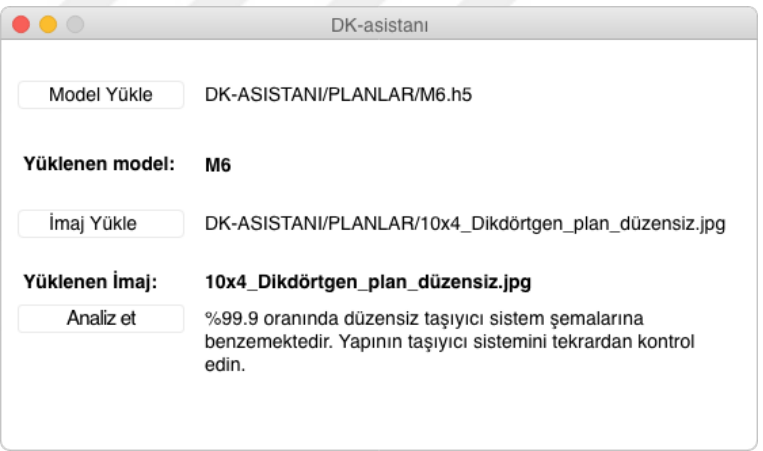
| Kat Genişliği B(y)  | Kat Genişliği B(x) | Kat ağırlık merkezi X(g) | Kat ağırlık merkezi Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|---|--------------------|--------------------------|--------------------------|---------------------------|---------------------------|
| 2000.00   | 1500.00            | 750.00                   | 1109.18                  | 750                       | 1195.96                   |
| <b>Dış Merkezlik Formülüne Göre Koordinatların Sonuçları</b>                        |                    |                          |                          |                           |                           |
| 1/20 B(y)   | 1/20 B(x)          | X(g-r)                   | Y(g-r)                   | X(g-r)<1/20(x)            | Y(g-r)<1/20(y)            |
| 100   | 75                 | 0                        | 86,78                    | 0 < 75                    | 0 < 100                   |
| <b>Sonuç: Düzenlidir.</b>   |                    |                          |                          |                           |                           |
| <i>B(y) = 2000.00cm, 1/20 B(y) = 100cm, y(G-R)= 86,78cm'dir. 86,78cm &lt; 100cm</i> |                    |                          |                          |                           |                           |




### 5.1.3. 10x4 Dikdörtgen Düzensiz Plan Şeması

Önceki plan şemalarından farklı olarak daha uzun tasarlanmış olan 10x4 Dikdörtgen Düzensiz Plan Şeması, DK-Asistanında test edildiğinde planın %99.9 oranında düzensiz sistem şemalarına benzediği görülmüştür. Tablo 7’de görüldüğü üzere, veri modellerinin tamamının %99 oranında düzensiz taşıyıcı sistem şemalarına benzerlik göstermiştir.

**Tablo 7: 10x4 Dikdörtgen Düzensiz Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması  |       | DK-Asistanı   |       |       |       |       |
|--|-------|---|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller   | M6    | M5  | M4    | M3    | M2    | M1    |
| Düzenli  | %0    | %2.9  | %2.4  | %7.0  | %1.2  | %1.3  |
| Düzensiz   | %99.9 | %99.9   | %99.9 | %99.0 | %99.9 | %99.9 |

**Prota-Structure Yazılımına Göre:** DK-Asistanının düzensiz olarak sınıfladığı bu plan şemasının ağırlık ve rijitlik merkezi farkı *Prota-Structure* yazılımına göre, Şekil 38’de görüldüğü gibi 952,59cm çıkmıştır. Tablo 8’deki analiz sonuçları ve dış merkezlik hesaplamasına göre yapının uzun kenarı toplam 4500 cm olup 1/20 uzunluğu 225cm olarak bulunmuştur. Ağırlık ve rijitlik merkezleri farkı (952,59cm), uzun kenarın 1/20’si değerinin üzerinde bir değere sahip olduğu için yapıda burulma riski ortaya çıkmaktadır.



**Şekil 38: 10x4 Dikdörtgen Düzensiz Planın Prota-Structure’ e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı**

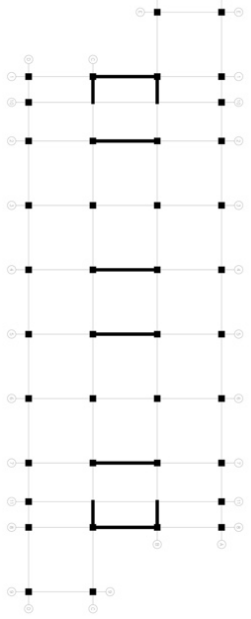
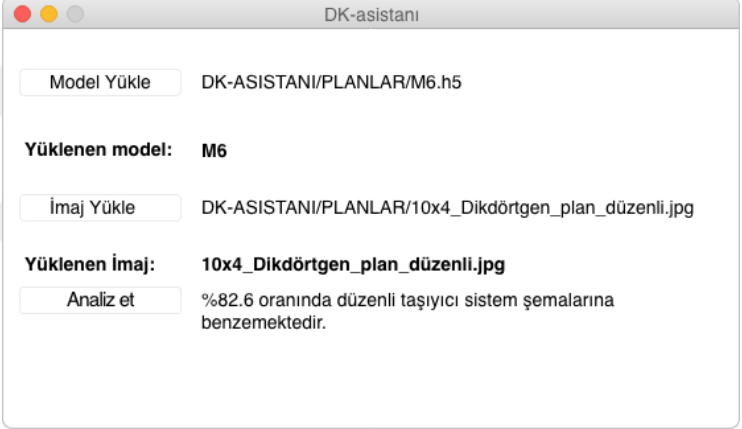
**Tablo 8: 5x4 Dikdörtgen Düzensiz Plan Şeması Ağırlık ve Rijitlik Merkezi Koordinatları ve Hesapları**

| Kat Genişliği B(y)  | Kat Genişliği B(x) | Kat ağırlık merkezi X(g) | Kat ağırlık merkezi Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|---|--------------------|--------------------------|--------------------------|---------------------------|---------------------------|
| 1500.00   | 4500.00            | 1904.27                  | 750.0                    | 750                       | 951.68                    |
| <b>Dış Merkezlik Formülüne Göre Koordinatların Sonuçları</b>  |                    |                          |                          |                           |                           |
| 1/20 B(y)   | 1/20 B(x)          | X(g-r)                   | Y(g-r)                   | X(g-r)<1/20(x)            | Y(g-r)<1/20(y)            |
| 75  | 225cm              | 0                        | 952.59                   | 0 < 225                   | 0 < 75                    |
| <b>Sonuç: Düzensiz.</b>   |                    |                          |                          |                           |                           |
| $B(x) = 4500.00\text{cm}$ , $1/20 B(x) = 225\text{cm}$ , $x(G-R) = 952,59\text{cm}$ 'dir. $86,78\text{cm} > 100\text{cm}$ (x) |                    |                          |                          |                           |                           |

#### 5.1.4. 10x4 Dikdörtgen Düzenli Plan Şeması

Bir önceki planın düzenli hali olan 10x4 Dikdörtgen Düzenli Plan Şeması DK-Asistanına göre M6, %82,6, M3, %98.1 oranında düzenli şemalara benzerlik sonucunu çıkartırken, M5, %97.5, M4, M2, M1, %99.9 oranında düzensiz şemalara benzerlik oranı çıkartmıştır. Bu tablodan anlaşıldığı üzere DK-Asistanı için eğitilen modeller, teste giren plan tiplerine göre farklı sonuçlar vermiştir. Tutarlı sonuç veren model özellikleri incelendiğinde ise M6 veri setinde daha gerçekçi ve plan tipleri bakımından daha karmaşık şema verileri içermektedir.

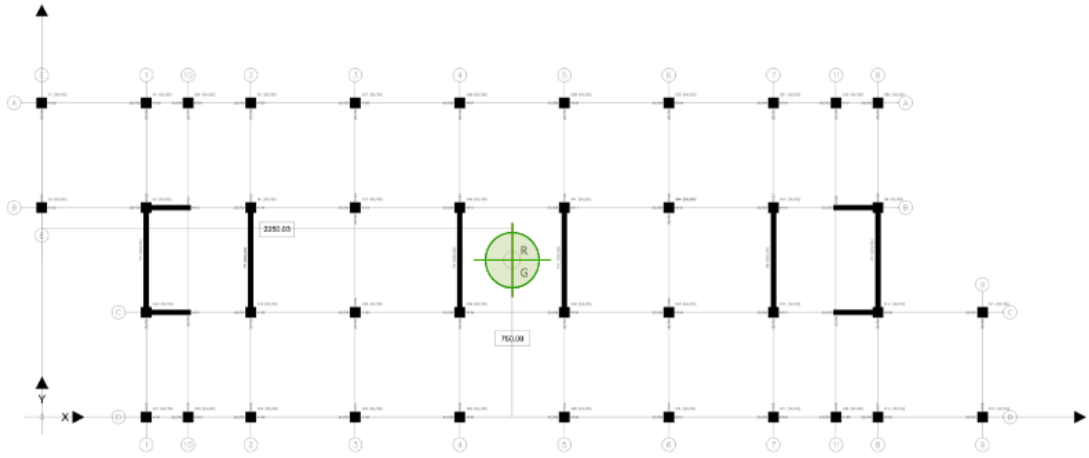
**Tablo 9: 10x4 Dikdörtgen Düzenli Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması  |       | DK-Asistanı   |       |       |       |       |
|--|-------|---|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller   | M6    | M5  | M4    | M3    | M2    | M1    |
| Düzenli  | %82.6 | %2.4  | %8.9  | %98.1 | %1.1  | %4.4  |
| Düzensiz   | %17.3 | %97.5   | %99.9 | %1.8  | %99.9 | %99.9 |

Öte yandan Tablo 9’da görüldüğü gibi M3 veri seti ise kolon tipleri bakımından çeşitlendirilmiş dikdörtgen plan şemalarından oluşmaktadır. M4 ise yalnızca kare plan tiplerinden oluştuğu için dikdörtgen özellikte olan planı doğru sınıflayamamıştır. Diğer modellerin vermiş olduğu tutarsız sonuçlar, veri setlerindeki çeşidin yetersiz olduğunu göstermektedir.

**Prota-Structure Yazılımına Göre:** *Prota-Structure* yazılımında test edilen bu planın, ağırlık ve rijitlik merkezlerinin birbirleri ile aynı konumda yer aldığı saptanmıştır. Şekil 39’da görüldüğü üzere, bu durum ağırlık ve rijitlik merkezi farkının 0 olduğunu göstermektedir. Tablo 10’te yer alan veriler incelendiğinde ağırlık ve rijitlik merkezlerinin farkının 0 olduğu görülmektedir. Bu durumda plan şemasında bu farktan kaynaklanan burulma riski mevcut değildir.

Bu durum ağırlık ve rijitlik merkezi farkının 0 olduğunu göstermektedir. Tablo 10 teki veriler incelendiğinde ağırlık ve rijitlik merkezlerinin farkının 0 olduğu görülmektedir. Bu durumda plan şemasında bu farktan kaynaklanan burulma riski mevcut değildir.



**Şekil 39:** 10x4 Dikdörtgen Düzensiz Planın Prota-Structure’a Göre Rijitlik ve Ağırlık Merkezlerinin Farkı

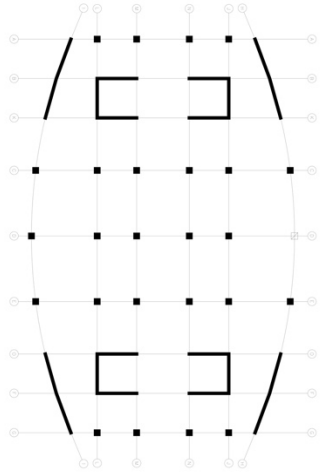

**Tablo 10:** Prota-Structure Koordinatları ve Dış Merkezlik Hesaplaması

| Kat Genişliği<br>B(y)  | Kat Genişliği<br>B(x) | Kat ağırlık<br>merkezi<br>X(g) | Kat ağırlık<br>merkezi<br>Y(g) | Kat rijitlik<br>merkezi<br>X(r) | Kat rijitlik<br>merkezi<br>Y(r) |
|--|-----------------------|--------------------------------|--------------------------------|---------------------------------|---------------------------------|
| 1500.00  | 4500.00               | 2250.03                        | 750.0                          | 2250.03                         | 750.0                           |
| Dış Merkezlik Formülüne göre koordinatların sonuçları            |                       |                                |                                |                                 |                                 |
| 1/20 B(y)  | 1/20 B(x)             | X(g-r)                         | Y(g-r)                         | X(g-r)<br>r<1/20(x)             | X(g-r)<br>r<1/20(y)             |
| 75   | 225cm                 | 0                              | 0                              | 0 < 225                         | 0 < 75                          |
| <b>Sonuç: Düzenli</b>  |                       |                                |                                |                                 |                                 |
| $B(x) = 4500.00cm, 1/20 B(x) = 225cm, x(G-R) = 0cm, 0cm < 100cm$ |                       |                                |                                |                                 |                                 |

### 5.1.5. 9x6 Elips Düzenli Plan Şeması


Tablo 11’de gösterildiği gibi 9x6 Elips Düzenli Plan Şeması, diğer plan tiplerinden farklı olarak elips plan tipine sahiptir. Burada denenen DK-Asistanının elips plan şeması için verdiği sonuçlardır. *Prota-Structure* yazılımında analiz edilmiştir. Rijitlik merkezi ile ağırlık merkezlerinin farkı 0 olduğundan, yapıda bu merkezlerden kaynaklan burulma düzensizliği riski saptanmamıştır.

**Tablo 11: 9x6 Elips Düzenli Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması  |       | DK-Asistanı   |       |       |       |       |
|--|-------|---|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller   | M6    | M5  | M4    | M3    | M2    | M1    |
| Düzenli  | %99.9 | %55.1   | %0.2  | %99.9 | %0.1  | %0    |
| Düzensiz   | %0    | %44.8   | %99.7 | %0    | %99.8 | %99.9 |

Elips planın DK-Asistanının düzenli ve düzensiz şemalarına (M1, M2, M3, M4, M5, M6) göre benzerlik oranı incelendiğinde %99 oranında M6 tipi düzenli şemalara, %55,1 oranında M5 tipi düzenli şemalara, %99,7 oranında M4 tipi düzensiz şemalara, %99,9 oranında M3 tipi düzenli şemalara, %99,8 oranında M2 tipi düzensiz şemalara, %99,9 oranında M1 tipi düzensiz şemalara benzediği görülmüştür.

**Prota-Structure Yazılımına Göre:** Tablo 12 ve Şekil 40'ta ağırlık ve rijitlik merkezlerinin koordinatları görülmektedir. Bu analize göre *Prota-Structure* yazılımı, yapının ağırlık ve rijitlik merkezi arasındaki farkı 0 olarak hesaplamıştır. Ağırlık ve rijitlik merkezi arasındaki fark, plan şemasının uzun kenarın 1/20'sinden az olduğu için, yapıdaki burulma riski saptanmamıştır.



**Şekil 40:** 9x6 Elips Düzenli Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı

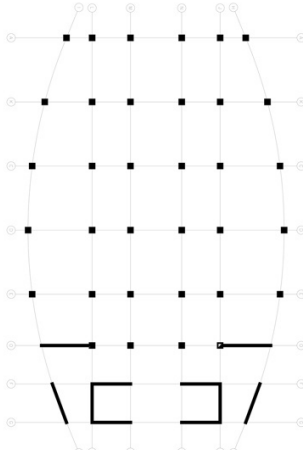
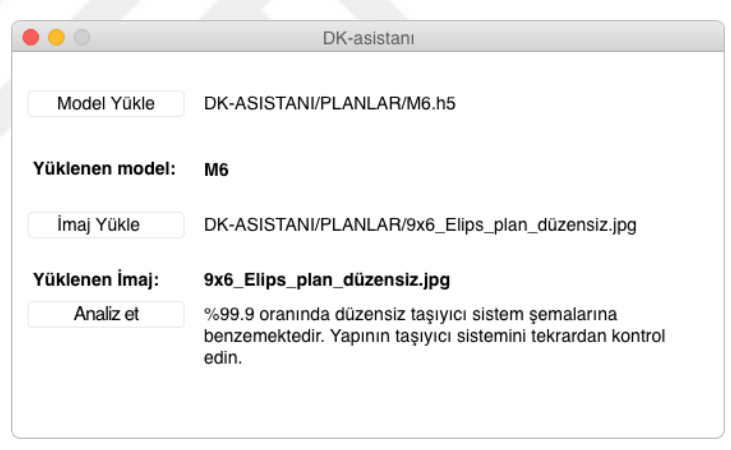
**Tablo 12: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması**

| Kat Genişliği B(y)   | Kat Genişliği B(x) | Kat ağırlık merkezi X(g) | Kat ağırlık merkezi Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|--|--------------------|--------------------------|--------------------------|---------------------------|---------------------------|
| 2000.00  | 3000.00            | 1500.00                  | 1000.00                  | 1500.00                   | 1000.00                   |
| <b>Dış Merkezlik Formülüne göre koordinatların sonuçları</b>   |                    |                          |                          |                           |                           |
| 1/20 B(y)  | 1/20 B(x)          | X(g-r)                   | Y(g-r)                   | X(g-r) < 1/20(x)          | Y(g-r) < 1/20(y)          |
| 100  | 150                | 0                        | 0                        | 0 < 150                   | 0 < 100                   |
| <b>Sonuç: Düzenli</b>  |                    |                          |                          |                           |                           |
| $B(x) = 3000.00\text{cm}$ , $1/20 B(x) = 150\text{cm}$ , $x(G-R) = 0\text{cm}$ , $0\text{cm} < 150\text{cm}$ |                    |                          |                          |                           |                           |

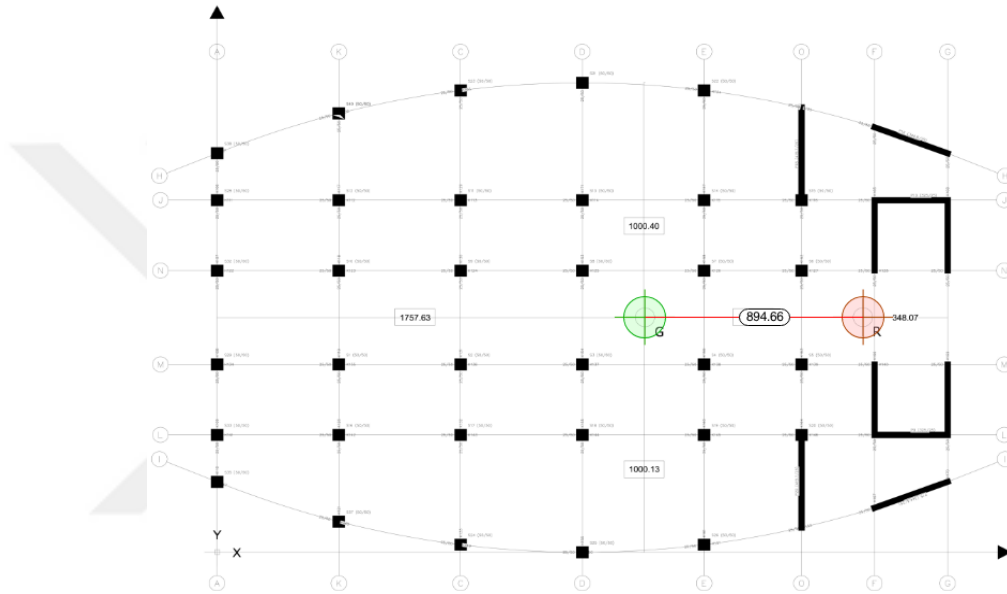
### 5.1.6. 9x6 Elips Düzensiz Plan Şeması

Şekil 41’de gösterilen 9x6 Elips Düzensiz Plan, Düzenli Planın simetrik yapısı bozularak elde edilmiştir. *Prota-Structure* yazılımındaki analiz sonucunda beklendiği gibi rijitlik ve ağırlık merkezleri arasında fark çıkmıştır. Tablo 13 görüldüğü gibi DK-Asistanı tarafından test edilen bütün veri setleri %99.9 oranında yapıyı düzensiz taşıyıcı sistem şemalarına benzetmiştir. Buradaki temel durum, Şekil 40’daki 9x6 Elips Düzenli Plan şemasının makineye öğretilen düzensiz taşıyıcı sistem şemalarına benzemesidir. Bu sayede makine karakterden çıkarım yaparak elips formundaki plan şemasını inceleyebilmiştir.

**Tablo 13: 9x6 Elips Düzensiz Plan Şeması ve DK-Asistanının Sonuçları**

| Plan Şeması   |       | DK-Asistanı  |       |       |       |       |
|---|-------|--|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller  | M6    | M5   | M4    | M3    | M2    | M1    |
| Düzenli   | %0    | %5.8   | %5.7  | %3.1  | %6.7  | %1.3  |
| Düzensiz  | %99.9 | %99.9  | %99.9 | %99.9 | %99.9 | %99.9 |

**Prota-Structure Yazılımına Göre:** Tablo 14 ve Şekil 41’de ağırlık ve rijitlik merkezlerinin koordinatları görülmektedir. Bu tabloya göre yapının x eksenini için ağırlık merkezi ile rijitlik merkezi farkı 894,66 cm’dir. Yapı x eksenini toplam uzunluğu 3000 cm olduğuna göre 1/20’si 150 cm’dir. Deprem yönetmeliğinde yer alan dış merkezlik formülüne göre incelendiğinde, fark 150 cm’den fazla olduğundan burulma düzensizliği oluşma riski vardır. Bu nedenle tasarımın ağırlık ve rijitlik merkezi arasındaki farkı 150cm veya daha küçük bir değere indirebilecek bir taşıyıcı sistem kurgusunun yapılması gerekmektedir.



**Şekil 41: 9x6 Elips Düzensiz Planın Prota-Structure’ e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı**

**Tablo 14: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması**

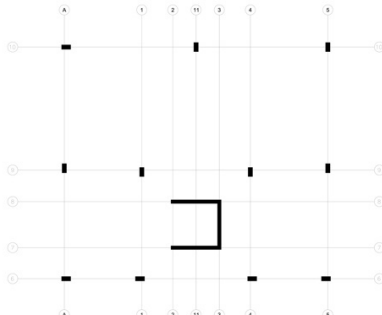
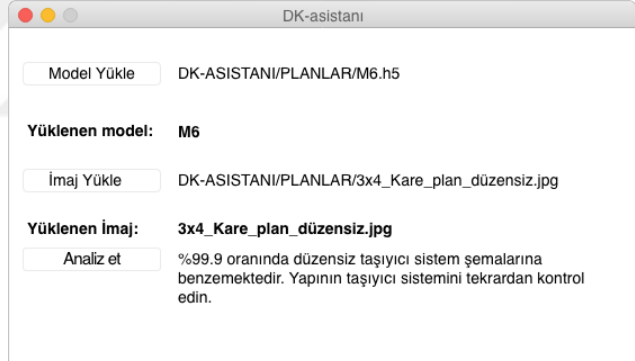
| Kat Genişliği B(y)  | Kat Genişliği B(x) | Kat ağırlık merkezi X(g) | Kat ağırlık merkezi Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|---|--------------------|--------------------------|--------------------------|---------------------------|---------------------------|
| 2000.00   | 3000.00            | 1757.63                  | 1000.00                  | 2652.29                   | 1000.00                   |
| <b>Dış Merkezlik Formülüne göre koordinatların sonuçları</b>              |                    |                          |                          |                           |                           |
| 1/20 B(y)   | 1/20 B(x)          | X(g-r)                   | Y(g-r)                   | X(g-r)<1/20(x)            | Y(g-r)<1/20(y)            |
| 100   | 150                | 894,66                   | 0                        | 0 < 150                   | 0 < 100                   |
| <b>Sonuç: Düzensiz</b>  |                    |                          |                          |                           |                           |
| $B(x) = 3000.00cm, 1/20 B(x) = 150cm, x(G-R) = 894,66cm, 0cm > 150cm (x)$ |                    |                          |                          |                           |                           |



### 5.1.7. 3x4 Kare Düzensiz Plan Şeması

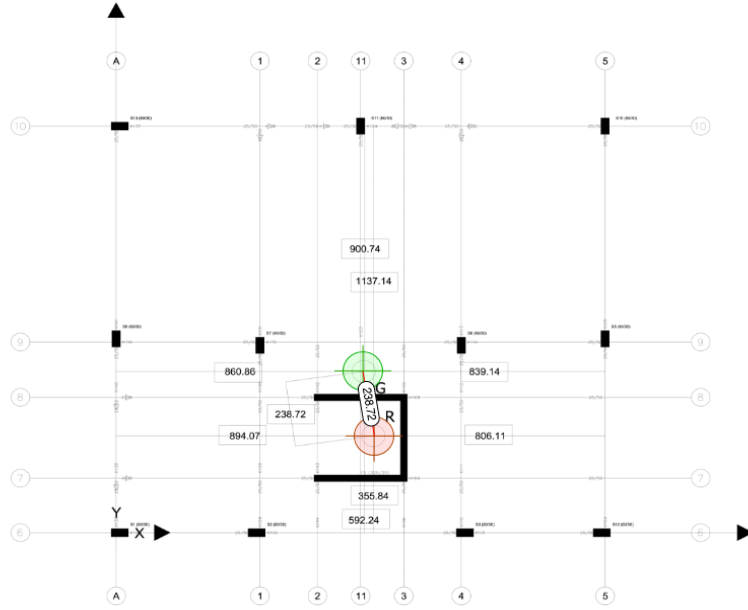
Tablo 15’de görüldüğü üzere DK-Asistanında test edilen 3x4 Kare Düzensiz Plan Şemasında burulma düzensizliği saptanmıştır. Bu düzensizlik durumu aynı zamanda *Prota-Structure* ile analiz edilerek, ağırlık ve rijitlik merkezlerinin farkları bulunmuştur. Bu plan şemasının diğer plan şemalarından farkı, yapı çekirdeğinin konumu nedeni ile burulma düzensizliğini meydana getirmesidir. Model sınıflarından M3, veri sınıfı bakımından dikdörtgen plan şemasına sahip ve kolon tipleri bakımından çeşitlendirilmiştir. Diğer modellere göre %92.9 oranında düzenli sonucunu vermiştir. Diğer modeller ise %99.9’luk bir oranla *Prota-Structure* yazılımı ile tutarlı sonuç vermiştir.

Tablo 15: Kare Düzensiz Plan Şeması ve DK-Asistanı Sonuçları

| Plan Şeması   |       | DK-Asistanı  |       |       |       |       |
|---|-------|--|-------|-------|-------|-------|
|  |       |  |       |       |       |       |
| Modeller  | M6    | M5   | M4    | M3    | M2    | M1    |
| Düzenli   | %0    | %2.2   | %8.7  | %92.9 | %9.2  | %0    |
| Düzensiz  | %99.9 | %99.9  | %99.9 | %7.0  | %99.9 | %99.9 |

### Prota-Structure Yazılımına Göre:

Tablo 16'daki sonuçlar incelendiğinde yapıda y eksenindeki rijitlik ve ağırlık merkezlerin farkından dolayı yapıda burulma riski mevcuttur. 1/20 kuralına göre planda uzun kenarın değeri 100 cm, ağırlık ve rijitlik merkezi farkı ise 236,4 cm'dir. Yapıda burulma düzensizliği vardır. Düzensizlik durumunu ortadan kaldırmak için yapının ağırlık ve rijitlik merkezleri arasındaki fark 100cm'den daha az olmak zorundadır.



Şekil 42: 3x4 Kare Düzensiz Planın Prota-Structure'e Göre Rijitlik ve Ağırlık Merkezlerinin Farkı

Tablo 16: Prota-Structure Koordinatları ve Dış merkezlik Hesaplaması

| Kat Genişliği B(y)   | Kat Genişliği B(x) | Kat ağırlık merkezi X(g) | Kat ağırlık merkezi Y(g) | Kat rijitlik merkezi X(r) | Kat rijitlik merkezi Y(r) |
|--|--------------------|--------------------------|--------------------------|---------------------------|---------------------------|
| 2000.00  | 1500.00            | 860.86                   | 592.24                   | 894.07                    | 355.84                    |
| <b>Dış Merkezlik Formülüne göre koordinatların sonuçları</b>                 |                    |                          |                          |                           |                           |
| 1/20 B(y)  | 1/20 B(x)          | X(g-r)                   | Y(g-r)                   | X(g-r)<1/20(x)            | Y(g-r)<1/20(y)            |
| 100  | 75                 | 34                       | 236,4                    | 0 < 75                    | 0 < 100                   |
| <b>Sonuç: Düzensiz</b>   |                    |                          |                          |                           |                           |
| $B(y) = 2000.00cm, 1/20 B(y) = 100cm, y(G-R) = 236,4cm, 236, cm > 100cm (x)$ |                    |                          |                          |                           |                           |

### 5.1.8. 7x4 Kare Düzensiz Plan Şeması

Tablo 17’de görüldüğü üzere, DK-Asistanı, 7x4 Kare Düzensiz Plan şeması test edilmiştir. DK-Asistanı bu plan şemasın M6 modeline göre %85.4 oranında düzensiz bulmuştur. Bu düzensizlik durumu *Prota-Structure* yazılımı ile doğrulanmıştır. Düzensizliğin ortaya çıkmasının sebebi perde duvarın konumu ve yoğunluğu olduğu anlaşılmaktadır. Diğer modeller ise bu plan şemasını %99.9 oranında düzensiz şemalara benzetmiştir.

**Tablo 17: 7x4 Kare Düzensiz Plan Şeması ve DK-Asistanı Sonuçları**

| Plan Şeması |       |       | DK-Asistanı |       |       |       |
|-------------|-------|-------|-------------|-------|-------|-------|
|             |       |       |             |       |       |       |
| Modeller    | M6    | M5    | M4          | M3    | M2    | M1    |
| Düzenli     | %14.5 | %1.2  | %0          | %0    | %0    | %0    |
| Düzensiz    | %85.4 | %98.7 | %99.9       | %99.9 | %99.9 | %99.9 |



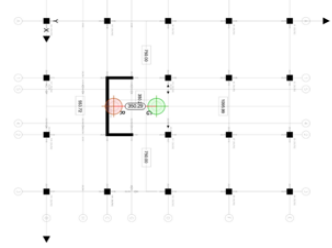
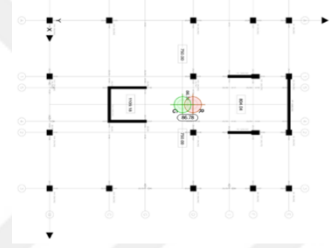
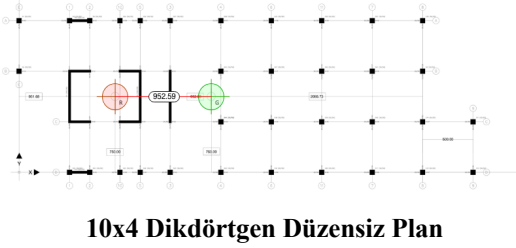
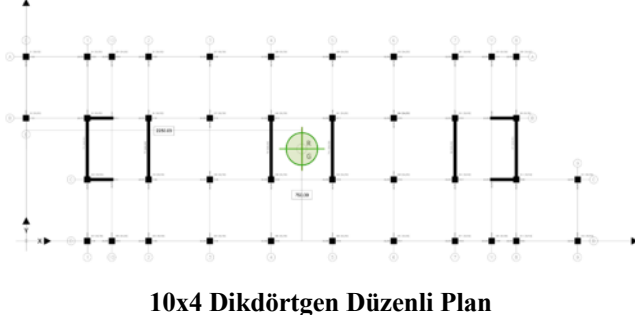
## 5.2. Test Sonuçları

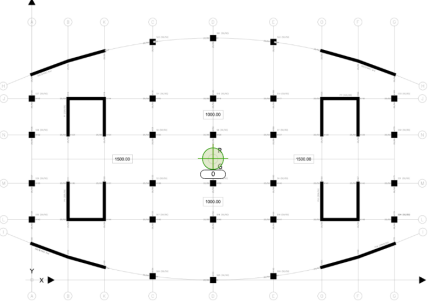
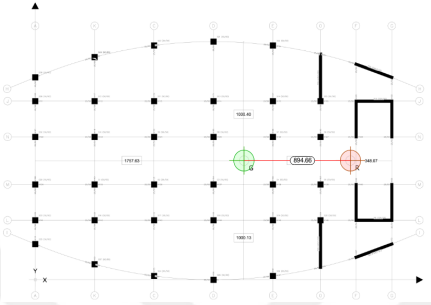
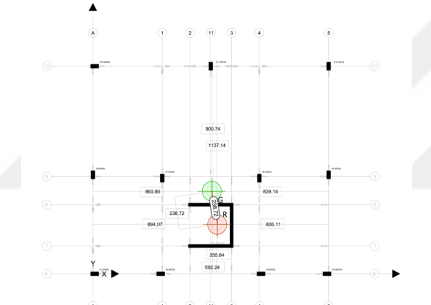
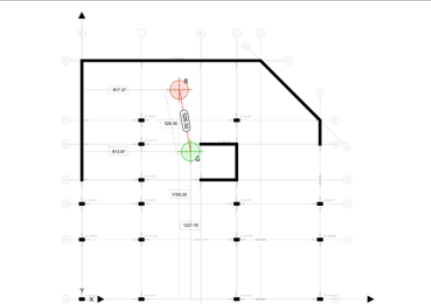
Sonuç tablosu incelendiğinde (Tablo 18), DK-Asistanı için eğitilen derin öğrenme modellerinin planlara göre verdikleri sonuçlar değişiklik göstermiştir. M6 modelinin içinde bulunan veriler çeşit ve ölçek bakımından gerçek planlara benzemektedir. M6 veri seti 8/8 oranda tutarlı tahminlerde bulunmuştur. Bu tahminler *Prota-Structure* yazılımından elde edilen veriler ile karşılaştırmalı olarak incelenmiştir. Diğer modeller incelendiğinde ise tutarlılık 8/8 tutarlılık oranları, 7/8 oranında M5, M4 ve M3, 6/8 oranda ise M2 ve M1 değişmektedir. Bu modeller M6'dan farklı olarak yalın şemalardan oluşmuştur.

M6'dan farklı olan diğer modeller, yalın plan şemalarından oluşmaktadır. Bu nedenle gerçek plan şemaları ile test edildiğinde M5 ve M4, 10x4 dikdörtgen düzenli plan ve 9x6 elips düzenli plan şemalarında; M3, 3x4 kare düzensiz plan şemasında; M1 ve M2'nin ise 5x4 dikdörtgen düzenli plan ve 10x4 dikdörtgen düzenli plan şemalarında tutarsız sonuç verdiği görülmüştür.

Derin öğrenme metodu ile oluşturulan modellerle, gösterilen 8 örnekte de taşıyıcı sistemin düzenli veya düzensiz olduğuna dair tahmin üretebilmiştir. Sonuç olarak kısıtlı sayıda üretilen şemalar ile yapılan test aşaması başarılı olmuştur.

Tablo 19: DK-Asistanı ve Prota-Structure Sonuçlarının Karşılaştırılması

| Planlar  | DK-Asistanı Sonuçları |       |       |       |       |       |       | Prota-Structure Sonucu<br>Dış merkezlik Formülü Kuralı: (G-R)<1/20B(x,y)  | DK-Asistanı ve Prota-Structure Sonuçlarının Karşılaştırılması |
|--|-----------------------|-------|-------|-------|-------|-------|-------|---|---|
|  | Modeller              | M6    | M5    | M4    | M3    | M2    | M1    |   |   |
|  <p>5x4 Dikdörtgen Düzensiz Plan</p>    | Düzenli               | %0.   | %1.0  | %0    | %0    | %4.0  | %1.1  | $B(y) = 2000.00\text{cm}$<br>$1/20 B(y) = 100\text{cm}$<br>$y(G-R) = 350,35\text{cm}$<br>$350,35\text{cm} > 100\text{cm} (\mathbf{x})$<br><b>Düzensiz</b> | <b>Sonuç: Tutarlı</b>   |
|  | Düzensiz              | %99.9 | %99.9 | %99.9 | %99.9 | %99.9 | %99.9 |   |   |
|  <p>5x4 Dikdörtgen Düzenli Plan</p>    | Düzenli               | %95.6 | %90.8 | %87.7 | %94.4 | %0.3  | %0.5  | $B(y) = 2000.00\text{cm}$<br>$1/20 B(y) = 100\text{cm}$<br>$y(G-R) = 86,78\text{cm}$<br>$86,78\text{cm} < 100\text{cm} (\checkmark)$<br><b>Düzenli</b>    | <b>Sonuç: Tutarlı</b>   |
|  | Düzensiz              | %4.3  | %9.1  | %12.2 | %5.5  | %99.6 | %99.4 |   |   |
|  <p>10x4 Dikdörtgen Düzensiz Plan</p> | Düzenli               | %0    | %2.9  | %2.4  | %7.0  | %1.2  | %1.3  | $B(x) = 4500.00\text{cm}$<br>$1/20 B(x) = 225\text{cm}$<br>$x(G-R) = 952,59\text{cm}$<br>$952,59\text{cm} > 225\text{cm} (\mathbf{x})$<br><b>Düzensiz</b> | <b>Sonuç: Tutarlı</b>   |
|  | Düzensiz              | %99.9 | %99.9 | %99.9 | %99.0 | %99.9 | %99.9 |   |   |
|  <p>10x4 Dikdörtgen Düzenli Plan</p>  | Düzenli               | %82.6 | %2.4  | %8.9  | %98.1 | %1.1  | %4.4  | $B(x) = 4500.00\text{cm}$<br>$1/20 B(x) = 225\text{cm}$<br>$x(G-R) = 0\text{cm}$<br>$0\text{cm} < 225\text{cm} (\checkmark)$<br><b>Düzenli</b>            | <b>Sonuç: Tutarlı</b>   |
|  | Düzensiz              | %17.3 | %97.5 | %99.9 | %1.8  | %99.9 | %99.9 |   |   |

|  |                       |                     |                     |                     |                     |                     |                  |  |                                     |
|--|-----------------------|---------------------|---------------------|---------------------|---------------------|---------------------|------------------|--|-------------------------------------|
|  <p><b>9x6 Elips Düzenli Plan</b></p>   | <p><b>Düzenli</b></p> | <p><b>%99.9</b></p> | <p><b>%55.1</b></p> | <p><b>%0.2</b></p>  | <p><b>%99.9</b></p> | <p><b>%0.1</b></p>  | <p><b>%0</b></p> | <p>B(x) = 3000.00cm<br/> 1/20 B(x) = 150cm<br/> x(G-R)= 0cm<br/> <u>0cm &lt; 150cm (✓)</u><br/> <b>Düzenli</b></p>       | <p><b><u>Sonuç: Tutarlı</u></b></p> |
| <p><i>Düzensiz</i></p>   | <p>%0</p>             | <p>%44.8</p>        | <p>%99.7</p>        | <p>%0</p>           | <p>%99.8</p>        | <p>%99.9</p>        |                  |  |                                     |
|  <p><b>9x6 Elips Düzensiz Plan</b></p>  | <p><i>Düzenli</i></p> | <p>%0</p>           | <p>%5.8</p>         | <p>%5.7</p>         | <p>%3.1</p>         | <p>%6.7</p>         | <p>%1.3</p>      | <p>B(x) = 3000.00cm<br/> 1/20 B(x) = 150cm<br/> x(G-R)= 894,66cm<br/> <u>0cm &gt; 150cm (x)</u><br/> <b>Düzensiz</b></p> | <p><b><u>Sonuç: Tutarlı</u></b></p> |
| <p><b>Düzensiz</b></p>   | <p><b>%99.9</b></p>   | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> |                  |  |                                     |
|  <p><b>3x4 Kare Düzensiz Plan</b></p>  | <p><i>Düzenli</i></p> | <p>%0</p>           | <p>%2.2</p>         | <p>%8.7</p>         | <p>%92.9</p>        | <p>%9.2</p>         | <p>%0</p>        | <p>B(y) = 2000.00cm<br/> 1/20 B(y) = 100cm<br/> y(G-R)= 236,4cm<br/> 236, cm &gt; 100cm (x)<br/> <b>Düzensiz</b></p>     | <p><b><u>Sonuç: Tutarlı</u></b></p> |
| <p><b>Düzensiz</b></p>   | <p><b>%99.9</b></p>   | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%7.0</b></p>  | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> |                  |  |                                     |
|  <p><b>7x4 Kare Düzensiz Plan</b></p> | <p><i>Düzenli</i></p> | <p>%14.5</p>        | <p>%1.2</p>         | <p>%0</p>           | <p>%0</p>           | <p>%0</p>           | <p>%0</p>        | <p>B(y) = 2000.00cm<br/> 1/20 B(y) = 100cm<br/> y(G-R)= 646.17cm<br/> 646.17cm &gt; 100cm (x)<br/> <b>Düzensiz</b></p>   | <p><b><u>Sonuç: Tutarlı</u></b></p> |
| <p><b>Düzensiz</b></p>   | <p><b>%85.4</b></p>   | <p><b>%98.7</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> | <p><b>%99.9</b></p> |                  |  |                                     |

## ALTINCI BÖLÜM

### SONUÇ

Mimari tasarım ve taşıyıcı sistem tasarımı her ne kadar farklı iki meslek gurubunun uzmanlık alanı gibi algılansa da, her iki tasarım süreci de temelde birbirinden bağımsız olmayıp aynı amaca hizmet etmektedir. Mimarların ve inşaat mühendisinin tasarım sorumluluklarını paylaştıkları bu süreçte, ortak bir terminolojiye gereksinim duyulmaktadır. Yapının asıl tasarımcısı olarak, avan proje aşamasından başlamak üzere bu açığı kapatma görevi özellikle mimarın üzerine düşmektedir.

Depremlerdeki can ve mal kaybının önüne geçebilmek için mimari tasarım ve strüktür tasarımı en başından itibaren dikkatle ve titizlikle yapılması gereken bir işlemdir. Öncelikli olarak mimarın yasa ve yönetmelikleri yeterince iyi bilmesi, burada yer alan hükümleri tasarımlarında doğru biçimde kullanması gerekmektedir. Mühendislik hesapları ne kadar doğru yapılmış olursa olsun, özen gösterilmeden yapılmış taşıyıcı sistem ve plan kurgusu tasarımları ile can ve mal kayıplarının önüne geçmek mümkün olamamaktadır.

Ülkemizin içinde bulunduğu coğrafya ve sahip olduğu deprem riski düşünüldüğünde, deprem mimarlığı büyük önem kazanmaktadır. Daha önce de belirtildiği gibi, depreme dayanıklı yapı tasarımı sadece inşaat mühendislerinin değil mimarların da sorumluluk alanına girmektedir. Bir yapının taşıyıcı sisteminin deprem yönetmeliğine uygunluğunu erken aşamada değerlendiren bir sistemin olması, mimari projelerin, statik projeleri aşamasında yaşanabilecek revizyonlarını en aza indirecektir.

Literatürdeki çalışmalar incelendiğinde yapay zekanın her alanda kullanımının yaygınlaştığı görülmektedir. Hastalık teşhisinden, dosya sınıflandırmaya kadar birçok alan bu teknolojiden faydalanmaktadır.

Yapay sinir ağları, biyolojik sinir sisteminde bulunan nöronların birbirleri ile ilişki kurması gibi, insandaki öğrenme işleyişinden hareketle geliştirilen ve nöron şeklinde tanımlanan yapılar, birbirleri ile bağlantılı olacak şekilde modellenmişlerdir. Algoritmalar bu sayede öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahip olmuştur. Buradan yola çıkarak bu çalışmada da derin



öğrenme ve görüntü sınıflandırma yöntemleri kullanılarak makinenin taşıyıcı sistemler hakkında tahminde bulunması hedeflenmiştir. Çalışmanın ilk aşamasında önerilen DK-Asistanı ile burulma düzensizliği testi yapılarak önerilen yöntem sınanmış ve değerlendirilmiştir. Tez kapsamında elde edilen sonuçlar, gerçek planlar üzerinden düzenli ve düzensizlik ayırımı yaparak sınıflandırma probleminin çözümünde derin öğrenme yönteminden yararlanılabileceğini göstermiştir.

Sonuçta insandaki öğrenme işleyişini taklit eden bu asistanla taşıyıcı sistemin düzenli mi yoksa düzensiz mi olduğuna dair tahmin alınabilmektedir. Tez kapsamında 6 farklı model oluşturulmuş ve veri setleri çeşitlendirilip sayısı çoğaltılmıştır. Bu sayede DK-Asistanının tutarlılık oranları artmıştır. Derin öğrenme ve görüntü sınıflandırmanın bu sürece dahil olarak, proje tasarımının erken aşamada hatayı tespit etmesi ve tasarımcıyı uyarması sağlanmıştır.

Gelecek çalışmalarda Deprem Yönetmeliği'nde yer alan diğer düzensiz bina tanımları (plandaki ve düşeydeki düzensizlikler) göz önünde bulundurularak veri setleri geliştirilip sayısı artırılabilir ve aynı çalışma mantığı ile makinaya öğretilerek gerçek planlar üzerinden test edilebilir. Fotoğraf üzerinden kısa sürede yorum yapabilen DK-Asistanının, hem deprem mimarlığı adına hem de inşaat mühendisliği adına faydalı bir sistem olacağı düşünülmektedir. Bu alanlarda yapılacak çalışmalarda M6 modelindeki gibi daha gerçekçi veya gerçek veri setleri ile oluşturulan modellerin eğitilmesi ile, DK-Asistanının, projelerin, deprem yönetmeliklerine ek olarak, ileride obje tanıma ve alan tanıma yöntemleri ile ilişkili, bağımsız alan, yangın, imar ve diğer başka yönetmelik maddelerine uygunluğunu da kontrol etmesi sağlanabilir.

## KAYNAKÇA

- Andrzej Kapanowski, M. S. (2014). *Python for Education: Permutations* . Python Papers Vol. 9, 1-17.
- Atalay, M., & Çelik, E. (2017). *Büyük Veri Analizinde Yapay Zeka ve Makine Öğrenmesi Uygulamaları*. Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 155-172.
- Bayboğan, B. Ç. (2013). *Tip İmar Yönetmeliğine Uygun Vaziyet Planı Üreten Bir Yapay Zeka Destek Sistemi*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Benjamin , Y., Courville, A., & Vincent, P. (2013). *Representation Learning: A Review and New Perspectives*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1798–1828.
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Springer-Verlag New York
- Celal, Z., & Kumbasar , N. (2004). *Deprem Mühendisliğine Giriş ve Depreme Dayanıklı Yapı Tasarımı*. İstanbul: Beta Dağıtım.
- Celeb, Z. (2018). *Deprem Mühendisliğine Giriş: Depreme Dayanıklı Yapı Tasarımı.*, Beta Basım Yayım Dağıtım A.Ş., İstanbul.
- Chollet, F. (2018). *Deep Learning with Python 1 ed*. NY 11964: Manning Publications Co. 20 Baldwin Road PO Box 761 Shelter Island.
- Cudzik, J., & Radziszewski, K. (2018). *Artificial Intelligence Aided Architectural Design, Gdansk University of Technology*. AI for Design and Built Environment, 77-84.
- Döndüren, S. M., Karaduman, A., Çöğürçü, T. M., & Altın, M. (2007). *Yapılarda Burulma Düzensizliği*. Selçuk Teknik Dergisi, 42-51.
- Deng, L. (2012). *Three classes of deep learning architectures and their applications: a tutorial survey*. Microsoft Research.

- DocsOpenCV. (2020). *Docs.OpenCV*. Erişim tarihi: 01 Ocak 2020, [https://docs.opencv.org/4.2.0/d0/de3/tutorial\\_py\\_intro.html](https://docs.opencv.org/4.2.0/d0/de3/tutorial_py_intro.html)
- Ersoy, U. (1985). *Betonarme: Temel İlkeler ve Taşıma Gücü Hesabı*. İnşaat Mühendisleri Odası.
- Ertel, W. (2009). *Under Graduate Topics Computer Science: Introduction to Artificial Intelligence*. Heidelberg New York: Springer London Dordrecht .
- Friedman, J. H. (1998). *Data Mining and Statistics: What's the connection?*. Computing Science and Statistics, 3–9.
- Günaydın, H. M., & Doğan, S. Z. (2004). *A Neural Network Approach for Early Cost Estimation of Structural Systems of Buildings*. International Journal of Project Management, 595–602.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press, 326.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Bengio, Y. (2014). *Generative Adversarial Networks*. Proceedings of the International Conference on Neural Information Processing Systems (NIPS 2014), 2672–2680.
- Huang, W., & Zheng, H. (2018). *Architectural Drawings Recognition and Generation through Machine Learning*. Proceedings of the 38th Annual Conference of the Association for Computer Aided Design in Architecture, 18-20.
- IBM. (2020). *What is batch processing?*. Erişim Tarihi: 01 Ocak 2020: IBM Knowledge Center: [https://www.ibm.com/support/knowledgecenter/zosbasics/com.ibm.zos.zconcepts/zconc\\_whatbatch.htm](https://www.ibm.com/support/knowledgecenter/zosbasics/com.ibm.zos.zconcepts/zconc_whatbatch.htm)
- İdemen, A. E. (2003). *Bina Ağırlık Merkezi- Rijitlik Merkezi İlişkisini Mimari Tasarım Aşamasında Kuran Bir Uzman Sistem*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Ünay , A. İ. (2002). *Tarihi Yapıların Depreme Dayanımı*. Ankara: ODTÜ Mimarlık Fakültesi Basım İşbirliği.

- Jennifer, N., Khean, N., Madden, D., Fabbri, A., Gardner, N., Haeusler, M. H., & Zavoleas, Y. (2019). *Optimising Image Classification - Implementation of Convolutional Neural Network Algorithms to Distinguish Between Plans and Sections within the Architectural, Engineering and Construction (AEC) Industry*. M. Haeusler, M. A. Schnabel, T. Fukuda (eds.), Intelligent & Informed - Proceedings of the 24th CAADRIA Conference - Volume 2, Victoria University of Wellington, Wellington, New Zealand, 15-18 April 2019, pp. 795-804
- Keras. (2020). *Keras: The Python Deep Learning library*. Erişim tarihi: 01 Ocak 2020. <https://keras.io/>
- Koza, J. R., Bennet, F. H., Andre, D., & Keane, M. A. (1996). *Automated Design of Both the Topology and Sizing of Analog Electrical Circuits Using Genetic Programming*. Artificial Intelligence in Design'96, 151–170.
- Kuhlman, D. (2013). *A Python Book: Beginning Python, Advanced Python, and Python Exercises*. Dave Kuhlman.
- Llamas, J., M Leronés, P., Medina, R., Zalama, E., & Gómez-García-Bermejo, J. (2017). *Classification of architectural heritage images using deep learning techniques*. Applied Sciences, 7(10), 992.
- Lu Pengzhen, S. C. (2012). Artificial intelligence in civil engineering. Mathematical Problems in Engineering, 22.
- Martin Abadi, E. B., Agarwal, A., Barham, P., & vd. (2020, 01 Ocak). *TensorFlow: Large- scale machine learning on heterogeneous systems*. Erişim tarihi: 01 Ocak 2020. <https://www.tensorflow.org/about/bib>
- Mathworks. (2020). Deep Learning. Mathworks. Erişim Tarihi: 01 Ocak 2020. <https://www.mathworks.com/discovery/deep-learning.html> adresinden alındı
- McCarthy, J. (2007). *WHAT IS ARTIFICIAL INTELLIGENCE?* Erişim tarihi: 01 Ocak 2020. [formal.stanford.edu](http://formal.stanford.edu)
- Mills, M. (2016). *Artificial Intelligence in Law: The State of Play 2016 (Part 1)*. Erişim tarihi: 01 Ocak 2020. <http://www.legalexecutiveinstitute.com/artificial-intelligence-in-law-the-state-of-play-2016-part-1/>

- Nabiyev, V. V. (2016). *Yapay Zeka - İnsan Bilgisayar Etkileşimi*. Ankara: Sözkesen Matbaacılık.
- Olafenwa, M. (2019). *Train Image Recognition AI with 5 Lines of Code*. Erişim tarihi: 01 Ocak 2020. Towards data science: <https://towardsdatascience.com/train-image-recognition-ai-with-5-lines-of-code-8ed0bdd8d9ba>
- OpenCV. (2020). *Open CV:About*. Erişim tarihi: 01 Ocak 2020. <https://opencv.org>: <https://opencv.org/about/>
- Patil, A., Patted, L., Tengai, M., & Jahagirdar, V. (2017). *Artificial Intelligence as a Tool in Civil Engineering - A Review*. IOSR Journal of Computer Engineering(IOSR-JCE), 36-38.
- Pirim, H. (2011). *Yapay Zeka*. Journal of Yaşar University, 81-93.
- Prota. (2020). Genel Bakış. Erişim tarihi: 01 Ocak 2020. <https://www.protayazilim.com/protastructure>
- Python. (2020). *Python*. Erişim tarihi: 01 Ocak 2020. <https://python.org>
- Radziszewski, K. (2017). *Artificial neural networks as an architectural design tool-generating new detail forms based on the Roman Corinthian order capital*. In IOP Conference Series: Materials Science and Engineering, 6.
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach (3rd ed.)*. Upper Saddle River, New Jersey: Prentice Hal.
- Smith, C., McGuire, B., Huang, T., & Yang, G. (2006). *The history of artificial Intelligence*. University of Washington, 27.
- Sonka, M., Hlavac, V., & Boyle, R. (2014). *Image processing, analysis, and machine vision*. Thomson.
- TBDY. (2018). *Afet ve Acil Durum Yönetim Başkanlığı, Türkiye Bina Deprem Yönetmeliği*, 19-30.
- Tuzcuoğlu, H. (2003). *Yapay Zeka Teknikleri, Depremde Kullanılması ve Küme Kuramları*. DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 73-88.
- Uzun, C., & Çorakoğlu, M. B. (2019). *Architectural Drawing Recognition-A case study for training the learning algorithm with architectural plan and section drawing images*. Design - ARTIFICIAL INTELLIGENCE - eCAADe 37, 29-34.

- Vasilev, I., Slater , D., Spacagna, G., Roelants, P., & Zocca, V. (2019). *Python Deep Learning: Exploring deep learning techniques and neural network architectures with Pytorch, Keras, and TensorFlow*. Livery Place 35 Livery Street Birmingham B3 2PB, UK: Packt Publishing Ltd.
- Waldrop, M. M. (2020). *News Feature: What are the limits of deep learning?* Eriřim tarihi: 01 Ocak 2020. <https://www.pnas.org/content/116/4/1074>
- Waziri, S. B., Bala , K., & Bustani, A. S. (2017). *Artificial Neural Networks in Construction Engineering and Management. International Journal of Architecture, Engineering and Construction*, 50-60.
- Wei, L. (2018). *Concepts in Architectural Design*. IOP Conf (s. 392,1-4). Materials Science and Engineering.
- Wiki Python. (2020, 01 01). Wiki Python: TKinter. Eriřim tarihi: 01 Ocak 2020. <https://wiki.python.org/moin/TkInter>
- Yılmaz, A. (2018). *Yapay Zeka*. Kodlab Yayınları.
- Yurtçu, ř., & Özocak , A. (2016). *İnce Daneli Zeminlerde Sıkıřma İndisi'nin İstatistiksel ve Yapay Zeka Yöntemleri ile Tahmin Edilmesi*. Journal of the Faculty of Engineering and Architecture of Gazi University, 597-608.

## EKLER

### EK-1 ÖZ GEÇMİŞ

#### KİŞİSEL BİLGİLER

**Soyisim, İsim** : BİNGÖL, Kaan  
**Uyruğu** : Türkiye Cumhuriyeti  
**Doğum Tarihi ve Yeri** : 01.08.1993 ÇANKAYA  
**Medeni Hali** : BEKAR  
**Telefon Numarası** : 0530 898 52 05  
**E-posta** : kaanbingol@outlook.com

#### Eğitim

| Derece        | Kurum                     | Mezuniyet Yılı |
|---------------|---------------------------|----------------|
| Lise          | Özel Aydın Anadolu Koleji | 2011           |
| Lisans        | Atılım Üniversitesi       | 2017           |
| Yüksek Lisans | Çankaya Üniversitesi      | 2020           |

#### İş Deneyimi

| Yıl        | Yer  | Pozisyon      |
|------------|--|---------------|
| 2013       | Timtaş Holding İnşaat A.Ş.                             | Stajyer       |
| 2015       | Lejant Proje Yapı End. Dan. Ltd Şti.                   | Stajyer       |
| 2017       | Tübitak BIGG 1512                                      | Girişimci     |
| 2018       | SS.Erzincan Demirciler Sanayi Koop.                    | Serbest Mimar |
| 2018       | Doğru Akyurt a İlçe Jandarma Komutanlığı Hizmet Binası | Serbest Mimar |
| 2019-Halen | Tübitak BIGG 1512                                      | Girişimci     |

#### Yabancı Dil

İyi Seviyede İngilizce (B2)  
Başlangıç Seviyesi Almanca (A2)

#### Hobiler

Planör, Yelkencilik