

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DEPREM SONRASI BETONARME KOLONLARDA BOYUNA DONATI
BURKULMASININ MAKİNE ÖĞRENMESİ İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

Bahadır GÜLEŞMEN

İnşaat Mühendisliği Anabilim Dalı

Yapı Mühendisliği Programı

HAZİRAN 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DEPREM SONRASI BETONARME KOLONLARDA BOYUNA DONATI
BURKULMASININ MAKİNE ÖĞRENMESİ İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

**Bahadır GÜLEŞMEN
(501211003)**

İnşaat Mühendisliği Anabilim Dalı

Yapı Mühendisliği Programı

Tez Danışmanı: Dr. Öğr. Üyesi Ömer Tuğrul TURAN

HAZİRAN 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**DETECTION OF LONGITUDINAL REINFORCEMENT BUCKLING IN
REINFORCED CONCRETE COLUMNS POST-EARTHQUAKE BY MACHINE
LEARNING**

M.Sc. THESIS

**Bahadır GÜLEŞMEN
(501211003)**

Department of Civil Engineering

Structural Engineering Programme

Thesis Advisor: Assist. Prof. Dr. Ömer Tuğrul TURAN

JUNE 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501211003 numaralı Yüksek Lisans Öğrencisi Bahadır GÜLEŞMEN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DEPREM SONRASI BETONARME KOLONLARDA BOYUNA DONATI BURKULMASININ MAKİNE ÖĞRENMESİ İLE TESPİTİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Ömer Tuğrul TURAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Murat YILMAZ**
İstanbul Teknik Üniversitesi

Prof. Dr. Bilge DORAN
Yıldız Teknik Üniversitesi

Teslim Tarihi : 29 Mayıs 2025
Savunma Tarihi : 17 Haziran 2025





Merhum Babam, Annem, Kardeşim ve Merve'ye



ÖNSÖZ

Tez çalışmasının hazırlanmasında emeği geçen, yönlendirme ve destekleriyle bu çalışmayı bilimsel temellere oturatarak şekillendirmemi sağlayan ve çalışmada kullanılan veri setinin oluşturulmasında büyük emek gösteren tez danışmanım Dr. Öğr. Üyesi Ömer Tuğrul TURAN'a teşekkür eder, saygılarımı sunarım.

Benden desteğini esirgemeyen ve hayatımdaki tüm zorluklarda yanımda olan annem Emine GÜLEŞMEN'e, kardeşim Yunus Emre GÜLEŞMEN'e ve Mervenur BOSTANCI'ya teşekkür eder, en içten sevgilerimi sunarım. Ayrıca, aramızdan ayrılmış olsa da desteğini her zaman hissettiğim merhum babam Recep GÜLEŞMEN'i rahmet ve özlemle anıyorum.

Mayıs 2025

Bahadır GÜLEŞMEN
(İnşaat Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
2. LİTERATÜR ÇALIŞMASI VE ARAŞTIRMA	3
2.1 Betonarme Kolon Burkulması.....	3
2.1.1 Global (Eksenel) burkulma	3
2.1.2 Lokal burkulma	4
2.1.3 Deprem etkisindeki kolon burkulması	7
2.2 Yapı Mühendisliği ve Yapay Zeka.....	8
3. VERİ SETİNİN OLUŞTURULMASI VE DÜZENLENMESİ.....	13
3.1 Veri Setinin Bölünmesi	15
3.2 Veri Setinin Özellikleri ve Sınırlayıcılar.....	16
4. DERİN ÖĞRENME MODELLERİ.....	19
4.1 Faster R-CNN Modeli	19
4.2 YOLOv8 Modeli	20
5. MODELLERİN EĞİTİLMESİ	23
5.1 Faster R-CNN Modelleri	23
5.1.1 Veri artırma teknikleri.....	23
5.1.2 Hiperparametreler	24
5.2 YOLOv8 Modelleri	25
5.2.1 Veri artırma teknikleri.....	25
5.2.2 Hiperparametreler	26
6. MODELLERİN DEĞERLENDİRİLMESİ.....	27
6.1 Faster R-CNN Modellerinin Değerlendirilmesi	29
6.2 YOLOv8 Modellerinin Değerlendirilmesi	31
6.3 Modellerin Performansının Karşılaştırılması	35
7. SONUÇLAR	39
KAYNAKLAR	41
ÖZGEÇMİŞ.....	47



KISALTMALAR

AE	: Autoencoder
AI	: Artificial Intelligence
ANN	: Artificial Neural Network
AP	: Average Precision
CCTV	: Close Circuit Television
CNN	: Convolutional Neural Network
COCO	: Common Objects in Context
SVM	: Support Vector Machines
FN	: False Negative
FP	: False Positive
GPU	: Graphics Processing Unit
IoU	: Intersection over Union
RC	: Reinforced Concrete
ROI	: Region of Interest
RPN	: Region Proposal Network
SGD	: Stochastic Gradient Descent
SHM	: Structural Health Monitoring
TP	: True Positive
YOLO	: You Only Look Once
CVAT	: Computer Vision Annotation Tool



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Burkulma bölgelerinin veri setine dağılımı.....	15
Çizelge 6.1 : Karışıklık matrisi.....	27
Çizelge 6.2 : ResNet modellerinin hiperparametreleri.	29
Çizelge 6.3 : ResNet modellerinin kutu tahmin performansı.	29
Çizelge 6.4 : ResNet modellerinin performans metrikleri.	30
Çizelge 6.5 : YOLOv8 modellerinin parametreleri.	32
Çizelge 6.6 : YOLO modellerinin kutu tahmin performansı.	32
Çizelge 6.7 : YOLO modellerinin performans metrikleri.	32
Çizelge 6.8 : Faster R-CNN(ResNet-152) ve YOLOv8m değerlendirme metrikleri	35



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1 : Kullanılan bazı boyuna donatı burkulma hasarı görüntüleri.	14
Şekil 3.2 : Donatı burkulmalarının etiketlenmesi.	15
Şekil 3.3 : Farklı ışık koşullarında burkulma hasarı fotoğrafları.	16
Şekil 3.4 : Farklı derinlik dolayısı ile sınırlayıcı kutuların iç içe geçmesi.	16
Şekil 3.5 : Farklı donatı koşulları.	17
Şekil 4.1 : Faster R-CNN mimarisi (Karim ve diğ. 2020).	20
Şekil 4.2 : YOLOv8 mimarisi (Yao ve diğ. 2024).	21
Şekil 6.1 : ResNet modelleri kesinlik-duyarlılık eğrileri.	30
Şekil 6.2 : ResNet-152 modeli donatı burkulması tahminleri.	31
Şekil 6.3 : YOLO modellerinin Kesinlik-Duyarlılık eğrileri.	33
Şekil 6.4 : YOLOv8m modeli donatı burkulması tahminleri.	34
Şekil 6.5 : Modellerin görüntü açısına karşı performansı.	36
Şekil 6.6 : Modellerin donatı benzeri şekillere karşı performansı.	37



DEPREM SONRASI BETONARME KOLONLARDA BOYUNA DONATI BURKULMASININ MAKİNE ÖĞRENMESİ İLE TESPİTİ

ÖZET

Bu tez çalışmasında, 6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş depremleri sonrasında, betonarme yapıların kolonlarında oluşan boyuna donatı burkulma hasarlarının fotoğraf üzerinden tespiti amacıyla derin öğrenme tabanlı nesne algılama modellerinin performansları karşılaştırmalı olarak incelenmiştir. Çalışmada, Faster R-CNN ve YOLOv8 olmak üzere iki farklı derin öğrenme tabanlı nesne algılama modeli değerlendirilmiştir. Faster R-CNN modeli, iki aşamalı yapısı sayesinde küçük ve lokalize hasar bölgelerinin hassas tespitinde güçlü bir performans sunarken; YOLOv8 modeli, hızlı ve tek aşamalı yapısıyla gerçek zamanlı uygulamalara uygunluğu ile öne çıkmaktadır.

Tezde kullanılan veri seti, deprem sonrası yapılan saha incelemeleriyle toplanan 539 yüksek çözünürlüklü görüntüden oluşmaktadır. Bu görüntülerde toplamda 1494 adet donatı burkulma bölgesi sınırlayıcı kutularla etiketlenmiştir. Veri seti eğitim (%80), doğrulama (%10) ve test (%10) alt kümelerine ayrılmış; görüntülerdeki farklı ışık koşulları, çekim açıları ve donatı çeşitliliği gibi zorluklar modellerin genelleme kapasitesini sınamıştır. Her iki model de bu veri seti üzerinde, çeşitli veri artırma teknikleri ve optimize edilmiş hiperparametrelerle eğitilmiştir.

Test verisi üzerinde yapılan değerlendirmeler sonucunda, YOLOv8m modeli en yüksek kesinlik (0.850) ve ortalama kesinlik (0.852) değerlerine ulaşmıştır. Bu model, 131 doğru pozitif (TP), 27 yanlış pozitif (FP) ve 29 yanlış negatif (FN) tahmin üretmiştir. ResNet-152 omurgasıyla Faster R-CNN modeli ise 135 TP, 106 FP ve 25 FN değerleriyle en yüksek duyarlılık (0.844) değerine sahip olmuştur. Bu sonuçlar, YOLOv8m modelinin daha yüksek doğruluk oranıyla yanlış tespit etme riskini azalttığını, buna karşın Faster R-CNN modelinin daha fazla hasar bölgesi tespit ederek kapsamlı bir tarama imkânı sunduğunu ortaya koymuştur.

Bu çalışma ayrıca, görüntülerin çekim açısı ve hasar bölgesinin görüntüdeki büyüklüğü gibi faktörlerin model performansına doğrudan etki ettiğini göstermiştir. Hasar bölgelerinin görüntüde daha geniş yer kapladığı durumlarda modellerin daha yüksek doğrulukla tahminler yaptığı gözlemlenmiştir. Bu bulgu, saha çalışmalarında yüksek kaliteli ve uygun açıda çekilmiş görüntülerin sağlanmasının önemini vurgulamaktadır.

Sonuçlar, iki modelin kendi içindeki karşılaştırılmasıyla hangi modelin hangi uygulamada daha avantajlı olacağını net bir şekilde ortaya koymaktadır. YOLOv8m modeli, yanlış tespit etme riskinin azaltılmasının ön planda olduğu durumlarda güvenilir bir çözüm sunarken; Faster R-CNN modeli, tüm hasar bölgelerinin eksiksiz tespit edilmesinin önemli olduğu senaryolarda daha uygun bir alternatif olarak değerlendirilmektedir. Böylece model seçimi, uygulama amacına ve projenin ihtiyaçlarına göre esnek bir şekilde yapılabilir.

Sonu olarak, bu tez alıřması her iki derin ğrenme modelinin de geleneksel hasar tespiti yöntemlerine göre ok daha hızlı, objektif ve kapsamlı bir özüm sunduğunu ortaya koymaktadır. Yapay zeka temelli bu yaklaşımlar, yapı mühendisliğı ve deprem sonrası hasar taramaları gibi alanlarda önemli bir potansiyele sahip olduğunu kanıtlamaktadır. Gelecekte veri setinin eřitlendirilmesi, üç boyutlu veri kümelerinin kullanılması ve daha gelişmiş derin ğrenme mimarileriyle modellerin performansının artırılması hedeflenebilir.



DETECTION OF LONGITUDINAL REINFORCEMENT BUCKLING IN REINFORCED CONCRETE COLUMNS POST-EARTHQUAKE BY MACHINE LEARNING

SUMMARY

This thesis explores the application of advanced deep learning-based object detection models for the automatic identification of reinforcement buckling damage in reinforced concrete columns following the devastating February 6, 2023, Turkey-Syria earthquakes. Reinforced concrete structures are the most widely used building systems, with columns serving as critical vertical load-bearing members that transfer loads from the superstructure to the foundation and the ground. The performance of these columns directly influences the overall stability and safety of structures, particularly during seismic events. Among the various types of structural damage, reinforcement buckling in columns is one of the most critical as it can significantly reduce the load-carrying capacity and overall stability of the structure.

The study employs two prominent deep learning-based object detection models—Faster R-CNN and YOLOv8—to comprehensively assess their effectiveness in detecting these critical structural damages. Faster R-CNN utilizes a two-stage architecture that provides high detection sensitivity for small and localized damage regions, which is essential for accurately identifying reinforcement buckling that may be difficult to observe visually. In contrast, YOLOv8 features a simplified single-stage architecture that enables real-time detection capabilities, making it advantageous for rapid post-disaster evaluations where rapid decision-making is paramount.

The dataset used in this thesis consists of 539 images collected from field investigations conducted after the earthquake, containing a total of 1494 reinforcement buckling instances annotated with bounding boxes. These images were carefully curated to include various challenges such as different lighting conditions (day and night), variable camera angles, and differences in reinforcement types, including ribbed and plain bars as well as corroded reinforcement. These variations introduced significant complexity, thereby testing the robustness of the models to real-world conditions and ensuring that the findings are widely applicable.

To optimize model performance, extensive data augmentation techniques were applied during training. These included horizontal flipping, random brightness adjustments, geometric transformations such as rotation and scaling, and color jittering to simulate the diverse environmental conditions present in the dataset. Hyperparameter tuning was also conducted to ensure stable convergence during training and to achieve the best possible detection performance. For the Faster R-CNN model, three backbone networks—ResNet-50, ResNet-101, and ResNet-152—were evaluated to examine how the depth of the network influences detection capability. Similarly, YOLOv8 was evaluated using all five of its model variants: YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, and YOLOv8x, each with varying levels of complexity and computational demands.

Model performance was evaluated on a test dataset, using several key metrics: precision, recall, F1 score, and average precision (AP). The YOLOv8m variant emerged as the best-performing model in terms of precision (0.850) and average precision (0.852), correctly identifying 131 true positive (TP) instances of reinforcement buckling while producing 27 false positive (FP) and 29 false negative (FN) predictions. Conversely, the Faster R-CNN model with the ResNet-152 backbone achieved the highest recall (0.844), detecting 135 true positives but with 106 false positives and 25 false negatives. These results highlight the distinct advantages of each model: YOLOv8m's precision-focused approach minimizes false alarms and enhances reliability, making it suitable for prioritizing urgent structural assessments and reducing the risk of unnecessary interventions. In contrast, Faster R-CNN's high recall ensures more comprehensive detection, which is particularly valuable in scenarios where a complete damage inventory is critical for decision-making.

Beyond numerical performance, this study also examined how various image characteristics influenced the models' predictive capabilities. Factors such as the size of the damage region within the image and the camera angle during capture had a notable impact on detection accuracy. Images in which the buckling damage occupied a larger portion of the frame consistently resulted in higher detection accuracy for both models. Conversely, images captured from side angles or with significant background clutter reduced detection performance. These findings underscore the importance of strategic image acquisition during field surveys and suggest that ensuring clear, well-framed images can significantly enhance the accuracy of automated detection systems.

The comprehensive evaluation extended to an internal comparison within each model family, guiding the selection of the most suitable variant for specific post-earthquake applications. The YOLOv8m model, with its balanced precision and recall (F1 score of 0.82), offers an optimal balance between accuracy and speed for scenarios where rapid assessments are essential. In contrast, the Faster R-CNN model with the ResNet-152 backbone, despite producing more false positives, ensures a broader and more thorough detection of potential damage regions, making it valuable in detailed inspections where missing any damage could have serious safety implications.

The study's findings highlight the importance of aligning model selection with specific assessment goals. In applications where minimizing false alarms is critical—such as emergency resource allocation and prioritization of repairs—the YOLOv8m model's high precision makes it the preferred choice. On the other hand, for comprehensive inspections requiring exhaustive documentation of all potential damage areas, the Faster R-CNN model's high recall offers a more suitable solution. By replacing labor-intensive and subjective visual inspections with automated evaluations, these models can streamline post-disaster damage assessments, providing consistent, objective insights that support data-driven decision-making and reduce the time required for comprehensive surveys.

Future researches include expanding the dataset to encompass a wider variety of real-world damage scenarios, incorporating three-dimensional data to provide richer structural insights, and developing hybrid approaches that combine YOLOv8's precision with Faster R-CNN's thorough coverage. Furthermore, the optimization of data augmentation strategies and the integration of advanced feature-fusion techniques has the potential to further enhance detection performance under challenging field conditions.

In conclusion, this thesis provides a comprehensive evaluation of deep learning-based object detection models for the rapid and reliable identification of reinforcement buckling damage in RC columns after earthquakes. The results demonstrate that these AI-driven models can significantly enhance the speed, consistency, and objectivity of post-disaster damage assessments. Structural engineers are able to adapt their methodologies to address the distinct requirements of various damage assessment scenarios by leveraging the distinct strengths of YOLOv8m and Faster R-CNN. This research contributes to the advancement of the field of automated structural health monitoring and supports the development of safer and more resilient urban environments in the context of seismic risks.





1. GİRİŞ

Betonarme yapılar günümüzde en çok tercih edilen yapı sistemleridir. Yapının düşey taşıyıcı sistemi olan kolonlar yükleri üstyapıdan temel ve zemine aktarırlar. Düşey yüklerin yanında yatay yükler için de önemli bir rol alan kolonlar deprem durumunda yapının dayanıklılığını belirler. Kolonların performansı yapının stabilitesi açısından hayati bir öneme sahiptir.

Burkulma hasarı kolonlarda oluşan yapısal hasar türleri arasında en kritiklerden biridir (Tripathi ve diğ. 2019). Betonarme kolonlarda burkulma, kolonların maruz kaldığı eksenel yükler ve deprem sırasında oluşan yatay yükler sebebiyle taşıma gücünü aşması ve böylece stabilitesini yitirmesiyle ani bir deformasyona uğramasıdır. Bu durum kolonun taşıma kapasitesini büyük ölçüde azaltarak yapısal sistem bütünlüğünü bozmaktadır. Deprem sonrasında kolonlarda oluşabilecek burkulma hasarı ağır yapısal sınıfa girer (Murray ve Sasani, 2017). Bu sebeple deprem bölgelerinde kolon burkulmalarının erken tespiti ve gerekli önlemlerin alınması, yapı hasarlarının ve can kayıplarının önüne geçmek için önem arz eder.

Günümüzde yapıların hasar tespiti ve değerlendirilmesi, çoğunlukla geleneksel yöntemler ve saha incelemeleriyle yapılmaktadır ancak bu yöntemler zaman alıcı ve subjektiftir. Bu nedenle hasar tespitinin hızlı, güvenilir ve objektif olabilmesi için yenilikçi yöntemlere ihtiyaç duyulmaktadır. Bu bağlamda makine öğrenmesi yöntemleri son yıllarda inşaat mühendisliğinde bazı alanlarda kullanılmaya başlanmış, hasar sınıflandırılması ve tespiti konusunda yüksek performans göstermiştir.

Bu tez çalışmasında, 6 Şubat 2023 Kahramanmaraş depremleri sonrası bölgedeki yapıların kolonlarında oluşan burkulma hasarının fotoğraflarının makine öğrenmesi yöntemleriyle tespit edilmesi üzerine bir araştırma ve uygulama gerçekleştirilecektir. Makine öğrenmesi algoritmalarıyla kolonlardaki burkulma hasarı otomatik olarak tespit edilecek ve bu yöntemlerin saha çalışmalarına göre etkinliği değerlendirilecektir. Ayrıca farklı makine öğrenmesi yöntemlerinin burkulma hasar tespiti konusunda etkinlikleri karşılaştırılacaktır. Çalışma sonucunda makine

öğrenmesi yöntemlerinin deprem hasar tespiti sırasında çekilen fotoğraflardaki betonarme kolonlardaki boyuna donatı burkulma hasar tespiti konusundaki potansiyeli ortaya konacaktır.



2. LİTERATÜR ÇALIŞMASI VE ARAŞTIRMA

Bu çalışma kapsamında, betonarme kolonların burkulma davranışı ve makine öğrenmesinin yapı mühendisliği alanındaki uygulamaları araştırılmıştır.

2.1 Betonarme Kolon Burkulması

Betonarme yapılarda düşey yüklerin temel ve zemine aktarılmasında büyük rol oynayan kolonlar, yapı bütünlüğü için önemli bir göreve sahiptir. Deprem veya herhangi bir yükleme durumunda tasarım yüklerinin aşılması, kolonların yük taşıma kapasitesini aşması halinde üst yapıların çökmesine varan hasarlar meydana getirebilir. Bu sebeple deprem sonrası betonarme kolonlarda oluşan burkulma hasarının tespit edilmesi kritik bir öneme sahiptir. Betonarme kolonlarda burkulma davranışı genel burkulma ve lokal burkulma olarak iki sınıfa ayrılır.

2.1.1 Global (Eksenel) burkulma

Genel burkulma, kolonun eksen boyunca eğilerek kısalmasıyla ortaya çıkan klasik Euler burkulmasıdır. Bu burkulmada kolon bir yay şeklini alır ve taşıma gücü kritik yük ile sınırlanır. Narin kolonlar genel burkulmaya daha eğilimlidir ve yapılardaki ara kat kolonlarında bulunan kesintisiz yüksek kolonlarda görülebilmesi daha olasıdır.

Narin kolonlar, uygulanan görece küçük yükler altında stabilitesini kaybederek global burkulma davranışını gösterebilir. Yüksek dayanımlı beton kullanılmasıyla kolon kesitlerinin küçülmesi kolonların narinliğini artırarak global burkulma ihtimalini artırabilir. Paultre ve diğ. (2001), yaptıkları deneysel çalışmada beton dayanımının artırılmasıyla sünek davranışın kötüleştiğini ve boyuna donatıların burkulmaya daha yatkın olduğu görülmüştür. Ek olarak bu çalışmada, yüksek dayanımlı beton kullanılan ve narin kolonlarda enine sargı kullanımının burkulma kapasitesini artırdığı ortaya konmuştur. Akademik çalışmalar genel burkulma davranışının, narin kolonlarda ikincil merteye etkiler ve stabilite kayıpları dikkate alınarak incelenmesi gerektiğini, yapılan analitik ve deneysel uygulamaların bazı tasarım kriterleri gerektirdiğini göstermiştir.

2.1.2 Lokal burkulma

Betonarme kolonlarda global burkulma olmadan yüksek deformasyonlar sonucu kolon içindeki boyuna donatılar burkulabilir. Bu burkulma kolon uç bölgelerinde plastik mafsalları oluşumu sırasında boyuna donatıların etriyelerin arasında burkulmasıdır ve deprem gibi tekrarlı yüklemelerde önemli bir hasar mekanizmasıdır. Kolon kesitinin çekirdeği etriye ile çevrilidir ancak örtü beton yüksek deformasyon seviyelerinde dökülür ve boyuna donatılar kısmen dışarı çıkar. Bu durum boyuna donatıların yanal olarak kısmen serbest kalmasına sebep olarak donatıda burkulma ihtimalini artırır. Etriye aralığının genişliği veya kenetlenme zayıflığı boyuna donatıların burkulma ihtimalini artırmaktadır. Bunların yanında lokal burkulma çekirdek betonun yanal desteğini kaybetmesini sağlayarak kolon dayanım ve sünekliğini azaltır (Çırak, 2011). Tripathi ve diğ. (2019) betonarme perdelerde farklı sınır bölgesi detaylandırmalarının donatı burkulmasını doğrudan etkilediğini ve bu etkinin perde elemanların süneklik ve enerji sönümleme kapasitelerini belirgin şekilde değiştirdiğini vurgulamıştır. Çalışmada farklı detaylandırmalara sahip betonarme perdelerin deneysel incelemesi sonucu, enine donatıların sıklaştırılması ve doğru şekilde konumlandırılmasının donatıların burkulma boyunu azalttığı ve bu sayede yapı elemanının genel performansını iyileştirdiği belirtilmiştir. Dhakal ve Su (2018), enine donatıların tasarımında, donatıların erken burkulmasını önleyecek yeterli yanal rijitliği sağlayacak kriterler geliştirmişlerdir. Araştırmacılar, donatı burkulma parametresini (donatı çapı, akma dayanımı ve burkulma boyunu birleştiren bir parametre) esas alarak geliştirdikleri yöntem ile tasarlanmış enine donatıların, donatı burkulmasını geciktirerek yapısal elemanın daha büyük plastik deformasyonlara ulaşabilmesine olanak sağladığını göstermişlerdir.

Donatıların basınç altındaki geometrik lineer olmayan davranışı ilk araştırma konularından biri olmuştur. Monti ve Nuti (1992), çevrimsel yüklemeye maruz kalan boyuna donatılarda lokal burkulmanın etkisini dikkate alan bir histeretik model geliştirmiştir. Çalışma, inelastik burkulmanın enerji sönümleme kapasitesini düşürdüğünü ve çevrimsel dayanımı azalttığını göstermiş; modelin, gerilme-şekil değiştirme döngülerini gerçekçi biçimde temsil edebildiği belirtilmiştir. Benzer şekilde Gomes ve Appleton (1997), örtü betonun dökülmesiyle yanal desteğini kaybeden donatıların lokal burkulmasını dikkate alan geliştirilmiş bir model önermiştir. Geliştirilen model, çevrimsel yük altında burkulma sonrası donatı

davranışını başarılı şekilde temsil ederek deneysel verilerle yüksek uyum sağlamıştır. Kashani (2024), boyuna donatıların inelastik burkulma davranışını ele aldığı derleme çalışmasında, mevcut deneysel ve sayısal modelleme yaklaşımlarını kapsamlı şekilde incelemiştir. Çalışmada, özellikle donatının etriye aralığında lokal olarak burkulmasının, kesit rijitliğinde azalma, plastik şekil değiştirme kapasitesinin düşmesi ve süneklik kaybı gibi kritik etkiler doğurduğu vurgulanmıştır. Mevcut modellerin bu karmaşık davranışı sınırlı doğrulukla temsil edebildiği, bu nedenle lokal burkulmanın daha gerçekçi simülasyonu için ileri modelleme tekniklerine ihtiyaç olduğu belirtilmiştir. Dhakal ve Maekawa (2002), lif modeli tabanlı bir modelleme çalışmasıyla boyuna donatıların akma sonrası burkulma hasarına bir analiz geliştirmiştir. Bu çalışmada geometrik kusurların önemine ve akma sonrasında boyuna donatıların basınç yönünde taşıma kapasitesinde büyük bir düşüş görülmüştür. Massone ve Moroder (2009), başlangıç kusurlarına sahip donatıların burkulma kapasitelerinin ciddi oranda azaldığını belirterek, bu tür kusurların burkulma davranışını modellemek için kritik olduğunu göstermiştir. Başlangıç kusurlarının simülasyonlarda dikkate alınmasının, donatıların burkulma kapasitelerini doğru bir şekilde öngörmekte önemli bir adım olduğunu deneysel ve nümerik olarak ispatlamışlardır. Kunnath ve diğ. (2009), boyuna donatıların burkulmasını içeren, betonarme yapıların doğrusal olmayan analizinde kullanmak adına tek eksenli bir malzeme modeli geliştirdi. Urmson ve Mander (2012), mekanik temelli bir analiz yöntemi geliştirerek boyuna donatıların lokal burkulma davranışını modellemiş ve etriye aralığına bağlı olarak kritik burkulma gerilmesini ve burkulma sonrası eksenel gerilme-şekil değiştirme ilişkisini tek bir analitik eğri ile tanımlamıştır. Bu analitik modeller, donatı burkulmasının kolonların moment-eğrilik ve yorulma davranışlarına etkisini anlamada önemlidir. Akkaya ve diğ. (2019), donatıların inelastik burkulma sonrası davranışını tanımlayan, deneysel verilerle doğrulanan basit ve pratik bir kurucu model önermiştir. Önerilen model, çeşitli deneysel ve analitik test sonuçlarıyla doğrulanarak, farklı malzeme ve geometrik özelliklere sahip donatıların burkulma davranışını başarılı bir şekilde öngörmüştür. Ayrıca bu model, donatıların tam kapsamlı gerilme-şekil değiştirme ilişkilerini tanımlamak için pratik bir yaklaşım sağlamıştır. Murray & Sasani (2017), sünek olmayan betonarme kolonlarda yaptıkları hibrit simülasyon çalışmasında, yüksek eksenel basınç ve yetersiz etriye aralığı nedeniyle boyuna donatılarda oluşan lokal burkulma mekanizmasını incelemiştir. Bu tür burkulmanın, ani taşıma gücü kaybına yol açtığı ve yapının genel davranışını

etkilediği gözlemlenmiştir. Çalışma, lokal donatı burkulmasının sistem düzeyinde yük aktarımı ve göçme riski üzerindeki önemine dikkat çekmektedir. Benzer şekilde Sagiroglu ve Sasani (2014), betonarme sistemlerde başlangıçtaki donatı burkulması gibi hasar türlerinin, ilerlemeli göçme senaryoları üzerindeki etkisini değerlendirmiştir ve lokal donatı burkulmasının sistem davranışında ikincil etkiler yaratabileceğine dikkat çekmektedir. McKee ve diğ. (2023) donatı burkulmasının mekanik ve geometrik özelliklere bağlı bir makro-mekanik model ile güvenilir şekilde tahmin edilebileceğini ortaya koymuşlardır. Önerilen model, donatıların burkulma sonrası oluşabilecek düşük çevrim yorulma hasarlarını ve bunların yapısal elemanların genel performansına etkisini doğru ve etkin bir biçimde modellemiştir.

Deneysel çalışmalar, modelleme çalışmalarının yanında donatıların burkulma davranışını destekler sonuçlar vermiştir. Moyer ve Kowalsky (2003), yaptıkları deneysel çalışmalarda, yaklaşık %6.5 çekme şekil değiştirmeleri altında olan boyuna donatıların, takip eden basınç yüklemelerinde daha hızlı burkulduğunu belirlemişlerdir. Özellikle yüksek düzeyde çekme geçmişine sahip donatılarda, bu durumun daha belirgin olduğu ve literatürde "çekme-temelli burkulma mekanizması" (tension-induced buckling mechanism) olarak adlandırıldığı ifade edilmiştir. Bae ve diğ. (2005), gerçekleştirdikleri kapsamlı deneysel çalışmada farklı çapa ve boyuta sahip toplam 162 boyuna donatıyı yalnızca basınç etkisi altında test ederek, donatıların burkulma sonrası malzeme davranışlarını incelemişlerdir. Çalışma, burkulma sonrasında donatıların aksenal taşıma kapasitelerinde belirgin bir azalma ve şekil değiştirme yeteneklerinde düşüş yaşandığını ortaya koymuştur. Çalışmada elde edilen veriler, sonlu eleman modellerine eklenebilecek şekilde bir malzeme modeli oluşturulmasına olanak sağlamış ve bu sayede plastik mafsallık bölgesinin daha gerçekçi biçimde modellenmesine katkı sağlamıştır. Tripathi ve diğ. (2018), düşük çevrimli tekrarlı yüklemeye maruz kalan boyuna donatıların inelastik burkulma davranışını deneysel olarak incelemiştir. Çalışmada, lokal burkulmanın, donatıların döngüsel deformasyon kapasitesini azalttığı, yorulma ömrünü kısalttığı ve enerji sönümleme kapasitesini düşürdüğü belirlenmiştir. Bu sonuçlar, deprem gibi tekrarlı yüklemelerde lokal burkulmanın yapısal performans üzerindeki kritik rolünü ortaya koymaktadır.

Boyuna donatı burkulmasının kolonun genel yapısal performansı ile ilişkisini araştıran önemli çalışmalardan biri Berry ve Eberhard (2005) tarafından sunulmuştur. Bu çalışmada, literatürde yer alan 100'ü aşkın betonarme kolon testinin bulguları

incelenerek, burkulma hasarının başladığı deplasman seviyelerini öngören ampirik denklemler geliştirilmiştir. Geliştirilen model; boyuna donatı oranı, enine donatı aralığı ve beton basınç dayanımı gibi değişkenleri dikkate alarak, donatı burkulmasının olduğu andaki görelî kat ötelemesi oranını tahmin etmektedir. Özellikle önerilen formüller, plastik dönme veya görelî kat ötelemesinin belirli bir sınır değerine ulaşması durumunda burkulmanın başladığını öngörmektedir. Bu türden parametrik ilişkiler, performansa dayalı deprem tasarımında kolonların göçme sınır durumlarını tanımlamak amacıyla kullanılabilir.

2.1.3 Deprem etkisindeki kolon burkulması

Betonarme kolonlar deprem etkisi altında tek yönlü statik yüklerden farklı olarak düşük çevrimli yorulma etkisi altındadır. İlk büyük deprem çevriminde kolon uç noktalarında plastik mafsall oluşabilir. Beton örtüsünün de dökülmesiyle bu bölgedeki donatılar burkulabilir. Sonraki tersinir çevrimde ise boyuna donatının burkulduğu bölgede yoğun bir plastik şekil değiştirme meydana gelebilir. Bu döngü, donatıda yorulma çatlaklarının oluşmasına ve birkaç çevrimde donatı kopmasına varan sonuçlar doğurabilir. Bu nedenle bir kolonun sismik yükler altındaki deformasyon kapasitesinin belirlenmesinde donatı burkulması önemli bir etkidir. Syntzirma ve diğ. (2010) çevrimsel yükleme altındaki donatı burkulmasının kolonların şekil değiştirme kapasitesi üzerindeki etkisini analitik olarak incelemişlerdir. Çalışmada ardışık çevrimlerin, çevrimlerin büyüklüğü ve sırası göz önüne alınarak burkulma kontrollü elemanların deformasyon kapasitesini önemli ölçüde etkilediği gösterilmiştir. Özellikle değişken genlikli yükleme senaryolarında, erken evrede meydana gelen büyük yer değiştirmeler, donatı burkulmasını daha erken tetikleyerek ilerleyen çevrimlerde bile dayanım kaybına neden olabilmektedir.

Betonarme kolonların sismik performansının değerlendirilmesinde kolonların taşıyıcılık ve süneklik üzerindeki etkisi pek çok çalışmaya konu olmuştur. Lehman ve diğ. (2004), sismik yüklemeler altında köprü kolonlarının performansını inceledikleri deneysel araştırmada, sargı detayları yetersiz olan kolonların burkulma ve hasar oluşumunun erken evrelerde başladığını tespit etmişlerdir. Buna karşılık, güncel yönetmeliklere uygun şekilde sık sargı donatısıyla tasarlanmış kolonlar, belirgin bir burkulma meydana gelmeden daha yüksek dönme taleplerine karşı dayanım göstermiştir. Elde edilen bulgular, yetersiz enine donatılı kolonların deprem sırasında

ani dayanım kaybına uğrayabileceğini ve bunun özellikle plastik mafsallarda bölgesinde hızlı kapasite azalmasına neden olabileceğini göstermektedir. Benzer şekilde, parametrik analizlere dayanan çalışmalar, kolonlarda donatı burkulmasının sismik performans üzerinde ciddi etkiler oluşturabileceğini göstermektedir. Su ve diğ. (2015), donatı burkulma etkisini basitleştirilmiş bir modelle yapısal analize dahil etmiş ve bu etkinin ihmal edilmesinin kolonun enerji tüketimi ve şekil değiştirme kapasitesinin gerçekte olduğundan daha yüksek tahmin edilmesine neden olduğunu ortaya koymuştur. Yapılan analizler, burkulmanın hesaba katıldığı durumlarda maksimum deplasman kapasitesi ve sönümlenme özelliklerinin daha düşük değerlere ulaştığını göstermiştir. Bu nedenle, modern performans değerlendirme yaklaşımlarında donatı burkulmasının, kritik bir limit durum olarak ele alınması gerektiği vurgulanmaktadır.

2.2 Yapı Mühendisliği ve Yapay Zeka

Yapı mühendisliğinde yapay zekânın kullanımı, son yirmi yılda hasar tespiti ve sınıflandırması alanında giderek artan bir şekilde uygulanmaktadır. Özellikle yapısal sağlık izleme (SHM) verilerinden hasar belirleme konusunda erken dönem çalışmalarda görüntü işleme teknikleri kullanılmıştır. Görüntü işleme tekniğiyle yapılan çalışmalarda binalar ve altyapılar değerlendirilmiş ve beton çatlaklar tespit edilmiştir. Tung ve diğ. (2002), yaptıkları çalışmada beton köprülerde oluşan çatlakların tespitini otomatikleştirebilmek için kamera görüntüleme sistemi geliştirmiştir. Abdel-Qader ve diğ. (2003), beton köprülerde çatlakları tespit etmek için Fourier dönüşümleri ve kenar algılama algoritmalarını uygulamıştır. Sinha ve Fieguth (2006), gömülü beton borular için filtre tabanlı bir çatlak algılayıcı geliştirmiştir. Benzer şekilde Yu ve diğ. (2007), betonarme bir tünel için entegre bir çatlak tespit sistemi önermiştir. Higgins ve Turan (2013), çelik levha bağlantılarının değerlendirilmesi ve derecelendirilmesi amacıyla kullanılan levha geometrisini hızlı şekilde toplamak için görüntü işleme ve yakın mesafe fotogrametri tekniklerini kullanmıştır. Wang ve diğ. (2023), bilgisayara dayalı görüntü işleme ve insansız hava araçları kullanarak yapı geometrisinin otomatik çıkarımına dayalı bir sistem önermiştir; çıkarılan verileri birleştirerek köprülerin sismik risk değerlendirmesi yapılmıştır.

Zamanla makine öğrenmesi tabanlı yaklaşımlarda kayda değer bir artış görülmüştür. Destek vektör makineleri (Support Vector Machines, SVM) ve yapay sinir ağları (Artificial Neural Networks, ANN) de hasar tespitinde kullanılan yöntemlerdir. Ho-Thu ve Mita (2013), yalnızca ilk üç doğal frekansı kullanarak yapısal hasar tespiti gerçekleştiren bir destek vektör makineleri modeli geliştirmiştir. Bu model, herhangi bir kat seviyesindeki hasarın yerini, sınırlı modal bilgiyle başarıyla belirleyebilmiştir. O'Byrne ve diğ. (2013), görüntülere dokusal özellikler ekleyerek altyapıdaki hasarları belirlemek için SVM sınıflandırma modellerini kullanmıştır. Lee ve diğ. (2013), beton yüzeylerdeki çatlakların genişlik, uzunluk ve yönlerini ölçmek için ANN kullanmıştır. Shimada ve diğ. (2006), farklı sınır koşullarına sahip yapılar üzerinde gerçekleştirdikleri çalışmada, her yapısal eleman için ayrı sınıflar tanımlayarak çok sınıflı SVM ile hasar tespitini yüksek doğrulukla gerçekleştirmiştir. O'Byrne ve diğ. (2014), yeni bir bölgesel olarak geliştirilmiş çok aşamalı segmentasyon tekniği sunmuş ve altyapıların korozyona uğramış yüzeylerini sınıflandırmak için SVM kullanmıştır. Bakhary ve diğ. (2010), çok aşamalı alt yapılandırma yaklaşımına dayanan bir yapay sinir ağı (ANN) sistemi geliştirerek, yapıların modal verilerini kullanarak hasar tespiti gerçekleştirmiştir. Doğal frekanslar ve mod şekilleri gibi dinamik parametreler, ağırlı girdi verisi olarak kullanılmış ve hem betonarme döşeme hem de çok katlı çerçeve sistemleri üzerinde çeşitli hasar senaryolarıyla yöntemin doğruluğu test edilmiştir. Elde edilen bulgular, bu yöntemin düşük seviyeli ve lokal hasarları dahi etkin biçimde belirleyebildiğini göstermektedir.

İlerleyen yıllarda derin öğrenme tekniklerinin gelişimiyle hasar sınıflandırılması ve tespiti konusunda büyük ilerleme sağlanmıştır. Özellikle görüntü verilerinin işlenmesi konusunda başarılı olan evrimsel sinir ağları (Convolutional Neural Networks, CNN), yapı hasarlarının tespitinde kullanılmaya başlanmıştır. Cha ve diğ. (2017), beton yüzeylerden elde edilen fotoğraflar aracılığıyla çatlak tespiti yapmak üzere özel yapılandırılmış bir derin öğrenme mimarisi geliştirmiştir. Eğitiminde 40.000'den fazla görüntü kullanılan bu CNN modeli, manuel özellik çıkarımı gerektirmeden ince ve görülmesi zor çatlakları yüksek doğrulukla tespit edebilmiş, test setinde yaklaşık %97 başarı sağlamıştır. Derin öğrenme, ham veriden özellikleri büyük ölçüde öğrenebildiği için, titreşim tabanlı hasar tespitinde de kullanılmıştır. Abdeljaber ve diğ. (2017), bir boyutlu CNN mimarisi kullanarak, ivmeölçerlerden elde edilen titreşim zaman serilerini doğrudan işleyen ve ön işleme gerektirmeden köprü tipi yapıların gerçek

zamanlı hasar tespitini gerçekleştiren bir yöntem önermiştir. Geliştirilen yaklaşım, deneysel olarak modellenmiş bir çelik köprü yapısında hasarın hem varlığını hem de konumunu insan müdahalesi olmadan başarıyla belirlemiş; ayrıca geleneksel yöntemlere kıyasla çok daha kısa sürede ve yüksek doğrulukla sonuç üretmiştir. Bazı araştırmacılar klasik CNN modellerini önceden büyük veri setleri ile eğiterek yapısal hasar tespiti için kullanılmıştır. Hassan ve diğ. (2019), önceden ImageNet üzerinde eğitilmiş AlexNet mimarisini transfer öğrenme yöntemiyle kanalizasyon borularının kapalı devre televizyon (Close Circuit TeleVision, CCTV) görüntülerine uyarlayarak, altyapı kusurlarını altı farklı sınıfta başarıyla sınıflandıran bir derin öğrenme sistemi geliştirmiştir (Krizhevsky ve diğ. 2017). 47.072 gerçek veriyle eğitilen bu model, farklı tipteki boru kusurlarını yüksek doğrulukla tespit etmiş ve altyapı denetiminde derin öğrenmenin potansiyelini ortaya koymuştur. Liu ve diğ. (2022), hasar almış binalardan toplanan çok sayıda görsel veriyi kullanarak, yapıların genel hasar durumunu otomatik sınıflandırabilen bir bilgi füzyonu tabanlı sistem geliştirmiştir. Çalışmada, binaya ait görüntülerden hasarın betonarme ve yığma bileşenlerine göre ayrı ayrı belirlenmesini sağlayan CNN tabanlı sınıflayıcılar eğitilmiş ve daha sonra bu bilgiler Naïve Bayes füzyon algoritması ile birleştirilerek binaya ait genel bir hasar sınıfı elde edilmiştir. Bu yaklaşım, saha verilerinin daha hızlı analiz edilmesini sağlayarak araştırma sürecini hızlandırmaktadır.

Görüntü tabanlı hasar tespitinde sadece sınıflandırma değil, hasarın konumunu tespit eden nesne tespiti yöntemleri de kullanılmıştır. Bu yöntemin kullanılması adına geliştirilen R-CNN modelleri, yapısal hasarı sınırlayıcı kutular sayesinde lokalize etmiştir. Cheng ve Wang (2018), iki aşamalı bir nesne algılama algoritması olan Faster R-CNN'i kullanarak kanalizasyon borularındaki çatlak, sızıntı, birikinti ve kök istilası gibi yaygın kusurları CCTV görüntüleri üzerinden otomatik olarak belirleyen bir yöntem geliştirmiştir. Yaklaşık 3000 görüntü üzerinde eğitilen bu derin öğrenme modeli, daha önce manuel olarak saatler süren video inceleme sürecini dakikalar içinde tamamlayarak kusurlu bölgeleri doğru biçimde tespit edebilmiş ve görsel incelemeyi yüksek doğrulukla hızlandırmıştır. Zhang ve diğ. (2020), insansız hava araçları ile elde edilen yüksek çözünürlüklü köprü görüntülerinde çatlak, dökülme, beton örtü kaybı ve donatı açığa çıkması gibi farklı hasar türlerini aynı anda tespit edebilmek amacıyla YOLO (You Look Only Once) tabanlı bir tek-aşamalı nesne algılama yöntemi geliştirmiştir. Çalışma kapsamında eğitilen YOLOv3 modeli, 2.206 görüntü ile

eğitilerek %80'e yakın bir ortalama doğruluk (Mean Average Precision, mAP) ile dört farklı hasar sınıfını başarıyla tanımlamıştır. Bu modelin, farklı ölçeklerdeki hasarları gerçek zamanlı olarak tek bir derin öğrenme mimarisiyle tespit edebildiği gösterilmiştir. Yao ve diğ. (2021), beton yüzeylerdeki çatlakları tespit etmek amacıyla, simetri özellikleri için optimize edilmiş ve sadeleştirilmiş bir YOLOv4 modelini önermiştir. Geliştirilen bu algoritma, 10.000 görüntüden oluşan bir veri kümesi üzerinde eğitilmiş ve %94,09 mAP (Mean Average Precision) elde ederek, mobil cihazlarda gerçek zamanlı hasar tespiti uygulamaları için kayda değer bir performans sergilemiştir. Lee ve diğ. (2023), yapının dinamik karakteristiklerini yansıtacak şekilde sonlu eleman modelleri oluşturmuş ve bu modeller üzerinde çeşitli hasar durumlarını modelleyerek bir eğitim veri seti oluşturmuştur. Bu verilerle eğitilen sinir ağı, hedef yapıda meydana gelen hasarın yerini ve şiddetini yüksek doğrulukla tahmin etmiş ve fiziksel modellemenin sağladığı yapısal analiz verisi ile yapay zekânın öğrenme kapasitesi birleştirilerek sınırlı veri ortamlarında bile etkili bir hasar tespiti yapabilmektedir. Han ve diğ. (2024), dijital ikiz yaklaşımını yapay zekâ tabanlı darbe tespitiyle entegre ederek Transfer-AE adını verdikleri yeni bir (Autoencoder, AE) mimari geliştirmiştir. Bu model, fiziksel yapılarla sayısal modeller arasındaki sistematik farkları azaltarak hem darbenin konumunu hem de şiddetini yüksek doğrulukla tahmin edebilmiş; böylece, özellikle fiziksel veri yetersizliğinin sorun olduğu durumlarda güvenilir yapısal sağlık izleme performansı göstermiştir. Iturburu ve diğ. (2024), betonarme yapıların taşıyıcı sistem özelliklerini yalnızca bina cephe görüntülerinden otomatik olarak çıkartabilmek amacıyla, bina görüntülerini kullanan yapay zekâ sistemi geliştirmiştir. Geliştirilen yöntem, sınıflandırıcı, nesne tespit edici ve poz tahminleyici olmak üzere üç aşamalı bir derin öğrenme mimarisine dayanmaktadır. Meksika'daki yapılardan oluşturulan veri setinde kolon ve kat bilgileri yüksek doğrulukla tahmin edilebilmiş ve bu sistemin, bina envanterlerinin oluşturulmasına katkı sağlayabileceği ifade edilmiştir.



3. VERİ SETİNİN OLUŞTURULMASI VE DÜZENLENMESİ

Bu çalışmada, 6 Şubat 2023 tarihinde Pazarcık ve Elbistan merkez üssü olmak üzere sırasıyla 7.8 ve 7.6 büyüklüğünde gerçekleşen depremler sonrasında bölgedeki betonarme yapıların hasar görüntüleri veri seti olarak oluşturulmuştur (Mai ve diğ. 2023).

6 Şubat 2023 Kahramanmaraş merkezli depremler sonucunda yapılan hasar tespit çalışmalarına göre 37.984 bina tamamen yıkılmış, 42.936 bina ağır hasar almış ve toplamda 300.649 bina çeşitli derecelerde hasar görmüştür. Bu yıkım ve hasarlar, çok sayıda yapının kullanılamaz hale gelmesine neden olmuştur (AFAD, 2023). Bölgede hasar belirleme çalışmaları kapsamında yapıların hasarları kaydedilmiş ve görüntüler depolanmıştır. Tez çalışmasında oluşturulmuş veri setinde birçok yapısal hasarın yanında betonarme kolonlarda meydana gelen boyuna donatı burkulma hasarına odaklanılmış ve bu hasar görselleri toplanarak veri seti oluşturulmuştur. Bazı boyuna donatı burkulma hasar görüntüleri Şekil 3.1’de gösterilmiştir.



Şekil 3.1 : Kullanılan bazı boyuna donatı burkulma hasarı görüntüleri.

Veri seti toplam 539 adet fotoğraf içermektedir ve bu fotoğraflarda toplam 1494 adet donatı burkulması bulunmaktadır. Bu fotoğrafları Şekil 3.2’de gösterildiği gibi sınırlayıcı kutular ile etiketlenerek derin öğrenme modellerinin eğitilmesi için hazırlanmıştır. Etiketleme işlemi, CVAT (Computer Vision Annotation Tool) aracı kullanılarak gerçekleştirilmiştir.



Şekil 3.2 : Donatı burkulmalarının etiketlenmesi.

3.1 Veri Setinin Bölünmesi

Veri seti, modelin öğrenme gücünü artırmak, hiperparametre optimizasyonunu sağlamak ve bağımsız test verisi ile objektif performans değerlendirmesi yapmak için literatürde yaygın önerilen %80 eğitim, %10 doğrulama ve %10 test oranına bölünmüştür (Golchubian ve diğ. 2021). Bölünme işlemi sonrası her veri setindeki burkulma bölgesi sayısı Çizelge 3.1’de verilmiştir.

Çizelge 3.1 : Burkulma bölgelerinin veri setine dağılımı.

Veri seti	Fotoğraf sayısı	Sınırlayıcı kutu sayısı
Eğitim	433	1196
Doğrulama	53	138
Test	53	160

3.2 Veri Setinin Özellikleri ve Sınırlayıcılar

Veri setini oluşturan hasar fotoğraflarını başka alanlarda yapılan derin öğrenme çalışmalarında kullanılan fotoğraf sayılarına göre görece azlığı kullanılan derin öğrenme modellerinin eğitim süreçlerini zorlaştıran bir etken olarak görülmektedir. Buna ek olarak fotoğrafların çeşitliliği, fotoğraf sayısının görece azlığının zorluğunu artırmaktadır.

Fotoğrafların farklı ışık ortamlarında (gece-gündüz) çekilmiş olması eğitim sürecini zorlaştıracak etkenlerden biridir. Bu durum Şekil 3.3'te gösterilmiştir.



Şekil 3.3 : Farklı ışık koşullarında burkulma hasarı fotoğrafları.

Ortam şartlarının yanında fotoğrafların çekilme açısı da eğitim sürecini zorlaştıran etkenlerden biri olabilmektedir. Bunun sebebi Şekil 3.4'te de görüldüğü gibi burkulma hasarına uğramış kolonun fotoğrafının karşıdan çekilmesi yerine başka bir yan açıdan çekilmesidir. Bu durum burkulma hasarını sınırlayan kutuların üst üste gelmesine sebep olup ve eğitim sürecini zorlayan faktörlerden biridir.



Şekil 3.4 : Farklı derinlik dolayısı ile sınırlayıcı kutuların iç içe geçmesi.

Son olarak fotoğraf çeşitliliğini artıran en büyük kriterlerden biri ise donatının durumudur. Yapılarda kullanılan çeliğin nervürlü veya nervürsüz olması durumu modelin eğitim sürecindeki negatif faktörlerden biridir. Burkulma hasarı tespit edilen kolonlardaki bazı donatılar nervürlü (Şekil 3.5(a)), bazı donatılar nervürsüz (Şekil 3.5(b)) olarak gözlemlenmiştir ve bunun yanında donatıların korozyona uğramış olması (Şekil 3.5(c)) sebebiyle de veri setinin çeşitliliği artmış, derin öğrenme modellerinin eğitim süreci bu gibi birçok sınırlayıcılar ile zorlaşmıştır.



(a) Nervürlü yapısal çelik



(b) Nervürsüz yapısal çelik



(c) Korozyon başlangıcı görülen yapısal çelik

Şekil 3.5 : Farklı donatı koşulları.




4. DERİN ÖĞRENME MODELLERİ

Bu çalışmada, betonarme kolonlarda deprem sonrası meydana gelen boyuna donatı burkulmalarının otomatik olarak tespit edilmesi için son yıllarda yüksek başarımla öne çıkan iki nesne algılama modeli kullanılmıştır: Bunlardan ilki olan Faster R-CNN modeli, iki aşamalı yapısı sayesinde özellikle küçük ve yerel hasar bölgelerinin tespitinde yüksek hassasiyet sağlamaktadır. Bu model kapsamında ResNet50, ResNet101 ve ResNet152 gibi farklı derinliklerdeki omurga ağları kullanılarak, ağ derinliğinin performansa etkileri de incelenmiştir (He ve diğ. 2016). Diğer taraftan YOLOv8 modeli, tek aşamalı ve yüksek hız sağlayan mimarisi sayesinde gerçek zamanlı uygulamalarda avantaj sunmaktadır Yaseen (2024). Bu çalışmada YOLOv8 modelinin n, s, m, l ve x versiyonları karşılaştırmalı olarak değerlendirilmiş, farklı ölçek ve derinlikteki modellerin performans etkileri analiz edilmiştir.

4.1 Faster R-CNN Modeli

Faster R-CNN iki aşamalı bir nesne tespit modelidir. İlk aşamada girdilerden özellik haritası çıkaran önceden eğitilmiş bir omurga ağından (ResNet-50/101/152) oluşur. Bu özellik haritası bölge öneri ağı (Region Proposal Network, RPN) katmanına bağlanır. RPN, görüntüyü farklı bağlantı kutuları ile taradıktan sonra hesapladığı puanlar ile bölge önerilerinde bulunur. İkinci aşama olan ilgi bölgesi havuzlama katmanı (Region of Interest, ROI) bu bölgeyi alır ve nesne sınıflandırması yapar (Ren ve diğ. (2015). Böylece Şekil 4.1’de mimarisi gösterilen Faster R-CNN modeli uçtan uca eğitilebilir bir sistemde hem bölge önerisi hem de sınıflandırma görevlerini gerçekleştirir (Karim ve diğ. 2020).




Şekil 4.1 : Faster R-CNN mimarisi (Karim ve diğ. 2020).

ResNet omurgaları Faster R-CNN modellerinde sıkça tercih edilir. ResNet-50/101/152, derinlikleri sırasıyla 50, 101 ve 152 katman olan kalınlaştırılmış evrimsel sinir ağlarıdır (Convolutional Neural Network, CNN). Bu ağlar giriş özelliklerini sonraki katmanın çıktısına toplayarak derin ağ eğitimi kolaylaştırır. ResNet-50 16 tane darboğaz katmanı içerirken, ResNet-101 33, ResNet-152 ise 50 tane darboğaz katmanı içerir. Bu modelin kapasitesinin artmasına ve bilgi genişliğinin artmasına sebep olur. Darboğaz katmanının artışı hassasiyet artışının yanı sıra, eğitim sürelerinin artmasına sebep olur ve bu sebeple hız-performans dengesini optimize ederek en doğru omurga seçilmelidir (He ve diğ. 2016).

4.2 YOLOv8 Modeli

Faster YOLOv8 mimarisi omurga (backbone), boyun (neck) ve kafa (head) olmak üzere üç ana bloktan oluşur. Mimari Şekil 4.2’de gösterilmiştir(Yao ve diğ. 2024). Omurga, özellik çıkarma adına tasarlanmış özel bir CNN omurgasıdır ve nesne tespiti için önemli olan anlamsal bilgileri temsil eden hiyerarşik bir özellik haritası oluşturur. Bu bölüm hem hız hem doğruluk açısından en iyi performans verecek şekilde evrimsel katmanlar ve YOLOv8 modelinde bulunan bilgi akışını optimize ederek genel performansı artıran C2f katmanı ile oluşturulmuştur. Boyun katmanı omurga katmanından gelen gelen özellik haritalarını birleştirerek nesne ayrımlarını daha iyi yapar ve daha küçük nesneleri daha iyi tespit eder. PANet (Path Aggregation Network) adı verilen yapı sayesinde farklı ölçeklerdeki özelliklerin birleştirilmesi için birleştirme (Concat) ve yeniden boyutlandırma (Unsample) katmanları ile modelin nesne tespiti konusundaki genel becerisi artırılmıştır. Kafa katmanı ise farklı çözünürlükteki özellik haritasından sınırlayıcı kutular, sınıf ve güven skorları üreten

üç tespit başlığı bulunur. YOLOv8 modelinde önceki modellerden farklı olarak çapasız (anchor-free) tespit başlıkları kullanılmıştır ve bu başlıklar sayesinde modelin hiperparametre ihtiyacı azalmış ve nesnelerin boyut farklarına karşı daha iyi performans sergilemiştir (Yaseen, 2024).



Şekil 4.2 : YOLOv8 mimarisi (Yao ve diğ. 2024).

YOLOv8 ihtiyaca göre 5 ana varyant içerir: YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x. Bu varyantlar aynı temel mimariye sahip olmalarına karşın katmanlardaki kanal sayısı ve derinlik farkları sebebiyle farklı doğruluk oranlarına sahiptir. Varyantlarda basitçe en küçük model olan YOLOv8n'den YOLOv8x'e kadar parametre artışı görülerek doğruluk değeri artar ancak hesaplama hızı düşer ve ek olarak hesaplama ve bellek kaynağı ihtiyacı artar (Ultralytics, 2023).



5. MODELLERİN EĞİTİLMESİ

Bu çalışmada deprem sonrası betonarme kolonlarda oluşan boyuna donatı burkulma hasarının tespit edilmesi için Faster R-CNN ve YOLOv8 modelleri kullanılacaktır. Faster R-CNN modellerinde ResNet-50, ResNet-101 ve Resnet-152 omurgalı olmak üzere 3 farklı model, YOLOv8 modeli için ise YOLOv8'de bulunan tüm varyantlar olmak üzere (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x) 5 model hazırlanan veri seti kullanılarak eğitilecek ve modellerin performansları ortaya konacaktır. Modellerin eğitimi aşamasında birçok veri artırma teknikleri ve hiperparametreler kullanılmıştır. Veri artırma teknikleri modelin eğitimi sırasında veri setinin çeşitliliğini artırma konusunda yardımcı olarak veri setini olası zorlayıcı ve gelecekte karşılaşılabileceği durumlara karşı hazırlamaya yardımcı olur. Hiperparametreler ise modelin eğitimi sırasında oluşan kayıp değerleri ve modelin doğrulama veri setindeki başarısına göre optimize edilerek modelin en optimum noktada çalışmasına katkı sağlamaktadır.

5.1 Faster R-CNN Modelleri

Veri seti üzerinde eğitilen üç Faster R-CNN modeli de ImageNet veri seti üzerinde önceden eğitilmiş modellerdir ve başlangıçta bu önceden eğitilen modellerin ağırlıkları kullanılmıştır.

5.1.1 Veri artırma teknikleri

Faster R-CNN modellerinin eğitiminde birçok veri artırma tekniği kullanılmıştır.

Bunlardan ilki, yatay çevirmedir ve bu veri artırma teknikleri fotoğrafın ve sınırlayıcı kutuların yatay ekseninde %50 olasılıkla çevrilmesidir. Kolon ve donatıların simetrik olmama durumuna karşı bir önlem olarak kullanılabilir ve burkulma bölgelerini daha kolay öğrenmesini sağlar.

Rastgele parlaklık tekniği de kullandığımız veri setinde karşılaştığımız bir durum olan farklı ışık koşullarında burkulma bölgelerinin tespit edilmesi konusunda model

için uygundur. Bu parlaklık değışikliğı fotoğrafın parlaklığının %50 oranında artırılıp veya azaltılmasıyla yapılır ve %50 ihtimalle uygulanır.

Renk oynatma tekniğı ile parlaklık, kontrast, doygunluk ve renk tonu değęerlerinin rastgele olarak değıştirilmesi ve modelin farklı durumlara adaptasyonunu geliřtirmesi hedeflenmiřtir. Parlaklık %20, kontrast %20, doygunluk %20 ve renk tonu 0.1 (yaklařık 36°) oranlarında rastgele artırılıp azaltılmıřtır. Bu veri artırma tekniğı %50 ihtimalle uygulanıyor olup, veri çeřitliliğinin artmasına katkı saėlamaktadır. Bu durum modelin kolon donatılarında oluřan korozyon gibi durumlara karřı adapte olabilmesine katkı saėlamaktadır.

Rastgele döndürme ile %50 ihtimalle fotoğraflar 10° iki yöne de döndürölür. Bu durum donatı burkulmalarının farklı açılardan çekilmesinin getirdiğı zorluklara karřı modelin performansını iyileřtirmesi adına kullanılmıřtır.

Rastgele ölçekleme, fotoğrafları 0.2 oranında küçölterek ve büyölterek yeniden boyutlandırır ve böylece yakından veya uzaktan çekilen fotoğraflarda burkulmanın farklı büyüklüklerde olmasına karřı model daha saėlam hale gelir. %50 ihtimalle uygulanır.

Dolgu ve kırpma işlemleri ise fotoğrafların boyutlarının eğitim süresince değıştirilmesiyle oluřabilecek boşlukların veya dolguların sırasıyla doldurulması ve kırılmasıdır. Bu işlem gereken her veri artırma adımında kullanılarak modelin her zaman sabit boyutlu fotoğraflar ile öğrenmeye devam etmesini saėlar. önceden eğitilmiş modellerdir ve bařlangıçta bu önceden eğitilen modellerin ağırlıkları kullanılır.

5.1.2 Hiperparametreler

Birçok hiperparametre modelin eğitimi için belirlenmiřtir. Yığın büyüklüğü (batch size) yani eğitim sürecinde her iterasyonda kullanılan fotoğrafların sayısı, kullanılan GPU (Graphics Processing Unit) belleğı de göz önüne alınarak 8 olarak belirlenmiřtir. Öğrenme oranı 0.01-0.001 aralığında değıştirilmiřtir ve 0.9 momentum değeri ile modelin daha hızlı ve kararlı yakınsamasını desteklenmiřtir. Her devirde modelin ağırlıklarının güncellenmesini saėlayan optimizatör, Stokastik Gradyan İniři (Stochastic Gradient Descent, SGD) olarak belirlenmiřtir. Ağırlık zayıflatma (weight decay) değeri öğrenme oranına baėlı olarak 0.001 ile 0.0001 arasında değıştirilmiřtir.

Bu hiperparametre modelin aşırı uyum (overfitting) sağlamasını engellemek adına kullanılan bir düzenleme tekniğidir.

5.2 YOLOv8 Modelleri

Bu çalışmada kullanılan YOLOv8 varyantları (n, s, m, l, x), MS COCO veri seti üzerinde önceden eğitilmiş ağırlıkları barındırmaktadır. İlk etapta bu ön-eğitilmiş ağırlıklar yüklenmiş; daha sonra transfer öğrenme yaklaşımı ile modeller, kolonlarda boyuna donatı burkulma hasarını içeren veri seti üzerinde ince ayara tabi tutularak güncellenmiştir. Önceden eğitilmiş modellerdir ve başlangıçta bu önceden eğitilen modellerin ağırlıkları kullanılır.

5.2.1 Veri artırma teknikleri

YOLOv8 modellerinin eğitiminde birçok veri artırma tekniği kullanılmıştır.

Mozaik birleştirme tekniği her yığında kullanılmıştır ve dört fotoğrafın birleştirilerek 2x2 halinde eğitilmesi sağlanır. Böylece model farklı ölçekteki burkulma durumlarına karşı daha dirençli hale gelerek küçük ve büyük burkulma bölgelerine karşı modelin daha iyi performans göstermesini amaçlamaktadır.

Karıştırma artırımı (MixUp) tekniği her fotoğraf için %50 ihtimalle aktif olur. İki fotoğraf ve etiketleri iç içe geçirilerek model eğitilir ve böylece modelin aşırı uyum sağlamasını engelleyerek daha sağlam genelleme yapmasına yardımcı olur.

Kullanılan bir diğer veri artırma tekniği türü de yatay çevirmedir. Bu yöntemde fotoğraflar %50 ihtimalle yatay çevrilir ve böylece simetri durumlarına yakalamak üzere model daha iyi eğitilmiştir.

Dikey çevirme tekniği ile birlikte görüntü dikey ekseninde çevrilir. Bu yöntem %20 kullanılmıştır çünkü dikey simetri durumları bizim veri setimizde nadir bir durumdur.

Fotoğrafların renk, parlaklık ve kontrast özelliklerine de yığınlarda rastgele şekilde düzenlemeler yapılarak veri setinin çeşitliliği artırılmıştır. Fotoğrafların tonu $\pm 1.5\%$ aralığında, doygunluğu $\pm 70\%$ aralığında ve parlaklık $\pm 40\%$ aralığında değiştirilerek modelin fotoğrafların farklı varyasyonlarına karşı daha iyi performans sağlaması amaçlanmıştır.

Fotoğraflar geometrik açıdan da bazı veri artırma teknikleri ile çeşitlendirilmiştir. Fotoğraflar $\pm\%10$ oranında yatay/dikey kaydırılmakta ve %50–150% arasında rastgele ölçeklenmektedir.

5.2.2 Hiperparametreler

Birçok hiperparametre modelin eğitimi için belirlenmiştir. Yığın büyüklüğü kullanılan GPU belleği de göz önünde bulundurularak 16 ve 32 birim olarak kullanılmıştır ve kullanılan modellerde performansa etkileri dikkate alınmıştır. Öğrenme oranı 0.01 olarak belirlenmiş ve 0.9 momentum değeri ile modelin optimizasyonu desteklenmiştir. Her devirde modelin ağırlıklarının güncellenmesini sağlayan optimizatör, Stokastik Gradyan İnişi (Stochastic Gradient Descent, SGD) olarak belirlenmiştir. Ağırlık zayıflatma (weight decay) değeri 0.0005 olarak kullanılmıştır.

6. MODELLERİN DEĞERLENDİRİLMESİ

Modellerin değerlendirilmesi, test veri setindeki performanslarının karşılaştırılması amacıyla çeşitli metrikler kullanılarak gerçekleştirilmiştir. Bu metrikler, eğitim veri setinde eğitilen modellerin test veri setindeki görüntüler üzerinde gerçekleştirdikleri tahminlerin sayısal verilere dönüştürülmesi yoluyla elde edilmiştir.

Modellerin test veri setindeki fotoğraflarda bulunan boyuna donatı burkulma hasarını içeren kutuların bazılarını doğru tahmin etmiş, bazılarını yanlış tespit etmiş ve bazı donatı burkulmalarını ise bulamamıştır. Modelin tahmin ettiği kutu, boyuna donatı burkulması içeren bir kutuysa doğru pozitif (true positive, TP), tahmin edilen kutu bir burkulma donatısı içermiyorsa yanlış pozitif (false positive, FP), bulamadığı burkulma hasarı kutuları ise yanlış negatif (false negative, FN) olarak değerlendirilmiştir. Bu değerlendirme Çizelge 6.1’de gösterilmiştir ve bu çizelge karışıklık matrisini de temsil etmektedir.

Çizelge 6.1 : Karışıklık matrisi.

	Gerçek burkulma durumu	Burkulma olmama durumu
Burkulma tahmini yapılması	TP	FP
Burkulma tahmini yapılmaması	FN	-

Model, burkulma bölgelerini tahmin ederken her bir bölge için bir güven skoru belirler ve böylece tahmin edilen kutunun doğruluk olasılığını nicelendirir. Bu güven skoru 0.5 ile sınırlandırılıp modelin güven skoru değerine 0.5 ve üzeri değerleri verdiği kutular dikkate alınmıştır. Ayrıca modelin tahmin ettiği burkulma kutularının gerçek burkulma kutuları ile kesişim oranı (Intersection over Union, IoU) da 0.5 ile sınırlandırılmıştır. Modelin tahmininin TP sayılabilmesi yani burkulma bölgesinin doğru tahmin edilebilmesi için güven skoru değerinin 0.5’ten büyük olması ve IoU değerinin 0.5’ten büyük olması gerekmektedir.

Modelin doğru tahminlerinin toplam pozitif tahminlere oranı kesinlik (precision) değerini ifade eder. Tahmin edilen kutuların gerçekten doğru olma oranını ifade eden kesinlik değeri denklem 6.1’de verildiği gibi hesaplanmaktadır.

$$Kesinlik = TP / (TP + FP) \quad (6.1)$$

Modelin doğru pozitif tahminlerinin toplam gerçek pozitif tahminlere oranı ise duyarlılık (recall) değerini ifade eder. Böylece modelin tüm burkulma kutularından kaçını bulabildiği tespit edilmiş olur. Duyarlılık değerinin hesaplanması denklem 6.2’de verilmiştir.

$$Duyarlılık = TP / (TP + FN) \quad (6.2)$$

Kesinlik ve duyarlılık metrikleri kendi başlarına modelin farklı açılardan performansını incelese de bu iki metriğin beraber değerlendirilmesi F1 skoru ile mümkündür. Bu iki metriğin harmonik ortalamasını veren F1 skoru denklem 6.3’de verildiği gibi hesaplanmaktadır. verilmiştir.

$$F1 \text{ skoru} = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (6.3)$$

Kesinlik ve duyarlılık değerleri test veri setinde yapılan tahmin değerlerine göre hesaplanır. Bu değerler hesaplandıktan sonra modelin genel performansını incelemek adına ortalama kesinlik (average precision, AP) değeri hesaplanır. Bu değer test veri setinde yapılan tahminlerin güven skorlarına göre sıralanmasının ardından en yüksek skorlu tahminden en düşük skorlu tahmine kadar her güven skoru eşliğinde yeni kesinlik ve duyarlılık değerleri hesaplanır. Bu her eşikte hesaplanan kesinlik-duyarlılık değerleri düşey eksen kesinlik yatay eksen ise duyarlılık olacak şekilde bir eğri olarak çizilir ve bu eğrinin altında kalan alan ortalama kesinlik değerini verir. En iyi performans gösteren modelin seçiminde genel performansı iyi bir şekilde ifade etmesi açısından ortalama kesinlik ilk dikkat edilen metrik olmuştur. Ortalama kesinlik değeri denklem 6.4’te verildiği gibi hesaplanmıştır.

$$Ortalama Kesinlik = \sum_{i=1}^N (Duyarlilik_i - Duyarlilik_{i-1}) Kesinlik_i \quad (6.4)$$

6.1 Faster R-CNN Modellerinin Değerlendirilmesi

ResNet-50/101/152 omurgalarından oluşan Faster R-CNN modelleri eğitim veri seti üzerinde eğitildikten sonra test veri setinde kesinlik, duyarlılık, F1 skoru ve ortalama kesinlik metrikleri açısından incelenmiştir. Bu 3 modelin test veri setindeki performansının incelenmesinin ardından en yüksek ortalama kesinlik değerine göre modeller belirlenmiş ve bu modeller kullanılmıştır. Bu modellerde kullanılan hiperparametreler Çizelge 6.2’de verilmiştir.

Çizelge 6.2 : ResNet modellerinin hiperparametreleri.

Model	Öğrenme oranı	Momentum	Ağırlık zayıflatma
ResNet-50	0.01	0.9	0.001
ResNet-101	0.005	0.9	0.0005
ResNet-152	0.01	0.9	0.001

Bu 3 modelin test veri seti üzerinde göstermiş olduğu performans; bulunan, yanlış bulunan veya bulunamayan kutuları ifade eden TP, FP ve FN değerleri ile değerlendirilebilir. Bu değer Çizelge 6.3’te verilmiştir.


Çizelge 6.3 : ResNet modellerinin kutu tahmin performansı.

Model	TP	FP	FN
ResNet-50	137	103	23
ResNet-101	137	94	23
ResNet-152	135	106	25


Modellerin yaptığı kutu tahminlerinin ardından, bu değerlerin kullanılmasıyla elde edilen performans metrikleri Çizelge 6.4’te verilmiştir. Ortalama kesinlik değerinin hesaplandığı Kesinlik-Duyarlılık (Precision-Recall) eğrileri Şekil 6.1’de gösterilmiştir. Eğriler grafiğin üstüne ve sağına ne kadar yakınsıyorsa yani eğri altında kalan alanı ne kadar büyütüyorsa model o kadar fazla performans verir denebilir.

Çizelge 6.4 : ResNet modellerinin performans metrikleri.


Model	Kesinlik	Duyarlılık	F1 Skoru	Ortalama Kesinlik
ResNet-50	0.570	0.856	0.684	0.762
ResNet-101	0.590	0.856	0.700	0.756
ResNet-152	0.560	0.844	0.673	0.779



(a) ResNet-50




(b) ResNet-101



(c) ResNet-152

Şekil 6.1 : ResNet modelleri kesinlik-duyarlılık eğrileri.

Yapılan sayısal hesaplamaların ardından ve Şekil 6.1’de de açıkça görüldüğü üzere ResNet-152 modeli en iyi performansı sergilemiştir. ResNet-152 modelinin test veri setindeki fotoğraflarda bulunan donatı burkulmalarına yaptığı bazı tahminler Şekil 6.2’de verilmiştir. Fotoğraflarda mavi kutular önceden etiketlenen gerçek burkulma bölgelerinin kutularıdır. Turuncu kesikli çizgiler ise eğitilen modelin yaptığı tahmin kutusudur. Tahmin kutusunun üstündeki değer güven skorunu belirtirken tahmin kutusunun altındaki değer ise kesişim oranı (IoU) değerini göstermektedir.



Şekil 6.2 : ResNet-152 modeli donatı burkulması tahminleri.

6.2 YOLOv8 Modellerinin Değerlendirilmesi

YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x modelleri eğitim veri seti üzerinde eğitildikten sonra test veri setinde kesinlik, duyarlılık, F1 skoru ve ortalama kesinlik metrikleri açısından incelenmiştir. Bu 5 modelin test veri setindeki

performansının incelenmesinin ardından en yüksek ortalama kesinlik değerine göre modeller belirlenmiş ve bu modeller kullanılmıştır. Modellerde kullanılan parametreler Çizelge 6.5’te verilmiştir. Bu parametreler, modellerin performansının en yüksek olduğu tespit edilen eğitim modelindeki parametre değerleridir.

Çizelge 6.5 : YOLOv8 modellerinin parametreleri.

Model	Öğrenme oranı	Momentum	Ağırlık zayıflatma	Yığın boyutu
YOLOv8n	0.01	0.9	0.0005	16
YOLOv8s	0.01	0.9	0.0005	32
YOLOv8m	0.01	0.9	0.0005	16
YOLOv8l	0.01	0.9	0.0005	16
YOLOv8x	0.01	0.9	0.0005	32

Kullanılan 5 YOLO modeli test veri setindeki fotoğraflar üzerinde tahminlerde bulunmuş ve bu tahminler sonucu elde edilen TP, FP ve FN değerleri Çizelge 6.6’da verilmiştir.

Çizelge 6.6 : YOLO modellerinin kutu tahmin performansı.


Model	TP	FP	FN
YOLOv8n	116	27	44
YOLOv8s	118	17	42
YOLOv8m	131	27	29
YOLOv8l	125	26	35
YOLOv8x	124	24	36

Modellerin yaptığı kutu tahminlerinin ardından, bu değerlerin kullanımıyla performans metrikleri hesaplanmıştır ve Çizelge 6.7’de verilmiştir.


Çizelge 6.7 : YOLO modellerinin performans metrikleri.

Model	Kesinlik	Duyarlılık	F1 Skoru	Ortalama Kesinlik
YOLOv8n	0.843	0.706	0.763	0.791
YOLOv8s	0.850	0.781	0.813	0.840
YOLOv8m	0.854	0.806	0.824	0.852
YOLOv8l	0.827	0.806	0.816	0.848
YOLOv8x	0.848	0.800	0.823	0.834


Çizelge 6.7’de hesaplanan veriler kullanılarak çizilen Kesinlik-Recall eğrileri ise Şekil 6.3’te verilmiştir.




(a) YOLOv8n




(b) YOLOv8s



(c) YOLOv8m




(d) YOLOv8l



(e) YOLOv8x

Şekil 6.3 : YOLO modellerinin Kesinlik-Duyarlılık eğrileri.

Çizelge 6.7’de verilen metrik değerlerine ve Şekil 6.3’te verilmiş olan eğrilerden de görüleceği gibi birçok modelin performansı birbirine yakındır ancak ortalama kesinlik değeri en yüksek olan ve kesinlik-duyarlılık eğrisinde de daha düzgün bir dağılım gösteren YOLOv8m modeli kullanılmaya en uygun model seçilmiştir. YOLOv8m modelinin test veri seti üzerinde yaptığı bazı tahminler Şekil 6.4’te verilmiştir.



Şekil 6.4 : YOLOv8m modeli donatı burkulması tahminleri.

6.3 Modellerin Performansının Karşılaştırılması

Eğitim ve test süreçlerinde üç Faster R-CNN(ResNet-50, ResNet-101 ve ResNet-152) ve beş YOLOv8 (n, s, m l ve x) modeli kullanılmıştır. Test verisi üzerindeki performans göz önüne alındığında Resnet-152 omurgalı Faster R-CNN ve YOLOv8m modeli donatı burkulmasının tespitinde en yüksek performansı göstermiştir. Bu iki modelin değerlendirme metrikleri Çizelge 6.8’de verilmiştir.

Çizelge 6.8 : Faster R-CNN(ResNet-152) ve YOLOv8m değerlendirme metrikleri


Model	Kesinlik	Duyarlılık	F1 skoru	Ortalama kesinlik
Faster R-CNN (ResNet-152)	0.560	0.844	0.673	0.779
YOLOv8m	0.854	0.806	0.824	0.852

Çizelge 6.8’de görüldüğü üzere, Faster R-CNN (ResNet-152) modeli, yüksek duyarlılık değeri (0.844) elde ederken, YOLOv8m modeli daha yüksek kesinlik değeri (0.854) göstermektedir. Bu durum, Faster R-CNN modelinin daha fazla pozitif örneği doğru şekilde yakalama eğiliminde olduğunu göstermektedir ve YOLOv8m modeline göre daha fazla burkulma tahmini yapmasına karşın oransal olarak bu tahminlerin doğruluk oranı daha düşüktür. YOLOv8m modelinin ise tespit ettiği pozitif örneklerin doğruluk oranının daha yüksek olduğu görülmektedir ve Faster R-CNN modeline göre toplam burkulma donatı sayısını daha az sayıda bulmuştur. Kesinlik ve duyarlılık metriklerinin arasındaki dengeyi ifade eden F1 skoru yönünden ise YOLOv8m modeli daha iyi performans göstermiştir. Ortalama kesinlik değerleri (AP), YOLOv8m’nin genel olarak tahmin kutularının gerçek burkulma kutularıyla daha iyi örtüştüğünü ve daha hassas sonuçlar ürettiğini ortaya koymaktadır.

Sonuç olarak, YOLOv8m modeli donatı burkulmasının tespitinde yüksek doğruluk oranı ve dengeli kesinlik-duyarlılık performansı ile avantajlı görünmektedir. Bununla birlikte, Faster R-CNN (ResNet-152) modeli daha yüksek duyarlılık oranıyla eksik tespitleri en aza indirerek, daha kapsamlı taramalar yapabilmektedir. Uygulama alanına bağlı olarak, olabilecek bir yanlış alarmın kritik olduğu durumlarda YOLOv8m modeli; tüm burkulmaların olabildiğince tespit edilmesinin önemli olduğu durumlarda ise Faster R-CNN (ResNet-152) modeli tercih edilebilir.


Modellerin bazı fotoğraf koşullarına karşı performansları da incelenmiştir. Test veri setinde modellerin tahmin yapması için kullanılan Şekil 6.5’te gösterilen fotoğraf,

görüntülenen açı sebebiyle birçok gerçek donatı burkulmasını içeren birçok kutunun bölgelerinin kesişmesini içerir. Şekil 6.5(a)'da Faster R-CNN (ResNet-152) modelinin yapmış olduğu tahminler, Şekil 6.5(b)'de ise YOLOv8m modelinin yapmış olduğu burkulma bölgesi tahminleri verilmiştir. Görüldüğü üzere Faster R-CNN modeli birçok tahmin yapmış fakat bu tahminlerin birçoğu yanlıştır. YOLOv8m modeli ise yaptığı tahminlerin hepsini doğru yapmasına rağmen bazı donatı burkulması bölgelerini yakalayamamıştır. Bu durum fotoğrafların çekilme açısının modellerin iyi performans göstermesini zorlaştırdığı görülmektedir.



Şekil 6.5 : Modellerin görüntü açısına karşın performansı.

Bir başka açıdan modelin bazı fotoğraf koşullarına sağladığı uyum Şekil 6.6'dan yola çıkarak açıklanmıştır. Şekil 6.6(a)'da Faster R-CNN modelinin yaptığı tahmin kutuları yer almaktadır ve görüldüğü gibi sol altta bulunan burkulmuş bir donatı şeklinde fakat donatı olmayan bir nesnenin tespit edildiği görülmektedir. Şekil 6.6(b)'de YOLOv8m modelinin tahminleri verilmiştir ve görüldüğü üzere aynı fotoğrafın yine aynı şekilde sol üstünde bulunan nesnenin tespit edilmediği görülmektedir. Buradan yola çıkarak YOLOv8m modelinin burkulma donatılarının tespitinde modeli zorlayabilecek bu gibi durumlara karşı daha iyi performans gösterdiği görülmektedir.



(a) Faster R-CNN (ResNet-152)

(b) YOLOv8m

Şekil 6.6 : Modellerin donatı benzeri şekillere karşı performansı.

Ayrıca iki modelin de donatı burkulmalarının tespitinde fotoğraf boyutlarının ve fotoğrafta bulunan burkulma donatısı bölgesini çevreleyen sınırlayıcı kutuların büyüklüklerinin bir önemi olduğu görülmüştür. Fotoğraf boyutlarının çok büyük olduğu fotoğraflarda yani görece donatı burkulmasına uzak bir konumdan çekilen fotoğraflarda donatı burkulmasını kapsayan sınırlayıcı kutunun resme göre çok küçük olması modelin performansını düşürmektedir. Bu sebeple büyük çözünürlüğe sahip fotoğrafların gereksiz kısımlarının kırılarak modelin eğitimi için kullanıldığında iki modelin de performansının arttığı gözlemlenmiştir. Liu ve diğ. (2022), yaptıkları çalışmada hasarlı bölgenin oranının tüm resme olan oranının en az %30 olması gerektiği ve performansın bu şekilde arttığını göstermiştir.



7. SONUÇLAR

Bu tez çalışmasında, 6 Şubat 2023 Kahramanmaraş depremleri sonrasında deprem bölgesinde hasar alan yapılardaki betonarme kolonlarda meydana gelen boyuna donatı burkulma hasarlarının, makine öğrenmesi tabanlı nesne algılama modelleri kullanılarak otomatik olarak tespit edilmesi amaçlanmıştır. Bu kapsamda Faster R-CNN ve YOLOv8 modelleri detaylı bir şekilde eğitilmiş ve performansları test edilmiştir.

Test verisinde yapılan performans ölçümlerine göre, ResNet-152 omurgalı Faster R-CNN modeli yüksek duyarlılık oranı (0.844) ile kolonlardaki burkulma bölgelerini tespit etme konusunda güçlü bir performans sergilemiştir. Buna karşın, YOLOv8m modeli daha yüksek kesinlik (0.85) ve ortalama kesinlik (0.852) değerleri ile dikkat çekmiş ve tespit edilen burkulma bölgelerinin doğruluk oranını artırmıştır. YOLOv8m modeli ayrıca kesinlik ve duyarlılık dengesini ifade eden F1 skoru (0.82) açısından da en iyi sonuçları elde etmiştir.

Her iki modelin de bazı avantajları ve sınırlamaları olduğu gözlemlenmiştir. Faster R-CNN modeli, daha fazla sayıda burkulma bölgesini tespit ederek kapsamlı bir tarama sağlamış; ancak yanlış pozitif tahmin sayısı görece yüksek olmuştur. Öte yandan, YOLOv8m modeli daha az yanlış pozitif tahmin yaparak güvenilirliğini kanıtlamış; ancak bazı gerçek burkulma bölgelerini kaçırabilmiştir. Bu durum, farklı uygulama ihtiyaçlarına göre modellerin seçiminde dikkate alınması gereken önemli bir parametre olarak öne çıkmaktadır. Örneğin, deprem sonrası hızlı tarama ve riskli bölgelerin öncelikli olarak belirlenmesi gereken durumlarda, daha yüksek duyarlılık sunan Faster R-CNN tercih edilebilirken; yanlış alarmın minimize edilmesinin önemli olduğu alanlarda YOLOv8m daha uygun bir seçenek olarak değerlendirilebilir.

Model performanslarının incelenmesinde ayrıca fotoğraf kalitesi, çekim açısı, ışık koşulları ve hasar bölgesinin fotoğraftaki büyüklüğü gibi etkenlerin önemli rol oynadığı tespit edilmiştir. Özellikle donatı burkulma bölgesinin görüntüde yeterli oranda temsil edilmesi model performansını doğrudan etkilemektedir. Bu gözlem,

saha çalışmalarında çekilen görüntülerin kalitesi ve çekim noktalarının önemini bir kez daha ortaya koymaktadır.

Çalışma sonucunda, hem Faster R-CNN hem de YOLOv8m modellerinin kolon burkulma hasarlarının otomatik tespiti için güçlü araçlar olduğu ve geleneksel yöntemlere kıyasla hızlı ve objektif sonuçlar sağladığı gösterilmiştir.

Yapay zeka tabanlı yaklaşımların deprem sonrası hızlı hasar tespitlerinde aktif olarak kullanılabileceğini çalışma ortaya koymaktadır. Böylece, afet sonrası müdahale süreçlerinin hızlandırılması ve riskli yapıların öncelikli olarak değerlendirilmesi mümkün hale gelebilecektir.

Veri setinin çeşitliliği ve zorluk seviyesinin model performansını etkilediği anlaşılmıştır. Özellikle farklı ışık koşulları ve çekim açılarında veri çeşitliliğinin artırılması, modellerin genelleme yeteneğini geliştirmek için önemlidir.

Ayrıca, veri setinin artırılması ve özellikle üç boyutlu veri kümelerinin kullanılması, modellerin kolon burkulma tespitinde daha kapsamlı bir değerlendirme yapmasına katkı sağlayacaktır. Ek olarak benzer veri setlerine farklı derin öğrenme modellerinin uygulanması dahilinde daha yüksek performans elde edilebilir ve mevcut modellerin zayıf yönleri giderilebilir.

Sonuç olarak, bu tez çalışması, makine öğrenmesi tabanlı hasar tespiti uygulamalarının yapı mühendisliği alanında önemli bir potansiyele sahip olduğunu göstermektedir. Geliştirilen ve test edilen modeller, deprem sonrası hasar belirleme süreçlerinde hızlı ve güvenilir bir alternatif sunmakta ve bu alanda yapılacak çalışmalara katkı sağlamaktadır.

KAYNAKLAR

- Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., & Inman, D. J.** (2017). Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, 388, 154–170. doi:10.1016/j.jsv.2016.10.043.
- Abdel-Qader, I., Abudayyeh, O., & Kelly, M. E.** (2003). Analysis of edge-detection techniques for crack identification in bridges. *Journal of Computing in Civil Engineering*, 17, 255–263. doi:10.1061/(ASCE)0887-3801(2003)17:4(255).
- AFAD.** (2023). 06 Şubat 2023 Pazarcık-Elbistan (Kahramanmaraş) Mw: 7.7 – Mw: 7.6 Depremleri Raporu (Yayın No. yok). Afet ve Acil Durum Yönetimi Başkanlığı, Deprem ve Risk Azaltma Genel Müdürlüğü. Erişim adresi: <https://www.afad.gov.tr>
- Akkaya, Y., Guner, S., & Vecchio, F. J.** (2019). Constitutive model for inelastic buckling behavior of reinforcing bars. *ACI Structural Journal*, 116, 195–204. doi:10.14359/51711143.
- Bae, S., Miseses, A. M., & Bayrak, O.** (2005). Inelastic buckling of reinforcing bars. *Journal of Structural Engineering*, 131(2), 314–321. doi:10.1061/(ASCE)0733-9445(2005)131:2(314).
- Bakhary, N., Hao, H., & Deeks, A.** (2010). Structure damage detection using neural network with multi-stage substructuring. *Advances in Structural Engineering*, 13(1), 95–110. doi:10.1260/1369-4332.13.1.95.
- Berry, M. P., & Eberhard, M. O.** (2005). Practical performance model for bar buckling. *Journal of Structural Engineering*, 131(7), 1060–1070. doi:10.1061/(ASCE)0733-9445(2005)131:7(1060).
- Cha, Y.-J., Choi, W., & Büyüköztürk, O.** (2017). Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361–378. doi:10.1111/mice.12263.
- Cheng, J. C. P., & Wang, M.** (2018). Automated detection of sewer pipe defects in closed-circuit television images using deep learning techniques. *Automation in Construction*, 95, 155–171. doi:10.1016/j.autcon.2018.08.006.
- Çırak, İ. F.** (2011). Betonarme binalarda gözlenen hasarlar, nedenleri ve öneriler. *SDU International Journal of Technological Sciences*, 3(3), 62–71.
- Dhokal, R. P., & Maekawa, K.** (2002). Modeling for postyield buckling of reinforcement. *Journal of Structural Engineering*, 128(9), 1139–1147. doi:10.1061/(ASCE)0733-9445(2002)128:9(1139).

- Dhakal, R. P., & Su, J.** (2018). Design of transverse reinforcement to avoid premature buckling of main bars. *Earthquake Engineering and Structural Dynamics*, 47, 147–168. doi:10.1002/eqe.2944.
- Golchubian, A., Marques, O., & Nojournian, M.** (2021). Photo quality classification using deep learning. *Multimedia Tools and Applications*, 80, 22193–22208. doi:10.1007/s11042-021-10766-7.
- Gomes, A., & Appleton, J.** (1997). Nonlinear cyclic stress-strain relationship of reinforcing bars including buckling. *Engineering Structures*, 19(10), 822–826. doi:10.1016/S0141-0296(97)00166-1.
- Han, C., Wang, Z., Fu, Y., Dyke, S., & Shahriar, A.** (2024). Transfer-AE: A novel autoencoder-based impact detection model for structural digital twin. *Applied Soft Computing*, 166. doi:10.1016/j.asoc.2024.112174.
- Hassan, S. I., Dang, L. M., Mehmood, I., Im, S., Choi, C., Kang, J., Park, Y.-S., & Moon, H.** (2019). Underground sewer pipe condition assessment based on convolutional neural networks. *Automation in Construction*, 106. doi:10.1016/j.autcon.2019.102849.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 770–778. doi:10.1109/CVPR.2016.90.
- Higgins, C., & Turan, O. T.** (2013). Imaging tools for evaluation of gusset plate connections in steel truss bridges. *Journal of Bridge Engineering*, 18, 380–387. doi:10.1061/(ASCE)BE.1943-5592.0000358.
- HoThu, H., & Mita, A.** (2013). Damage detection method using support vector machine and first three natural frequencies for shear structures. *Open Journal of Civil Engineering*, 3(2), 104–112. doi:10.4236/ojce.2013.32012.
- Iturburu, L., Liu, X., Zhang, X., Wogen, B. E., Villamizar, J. N., Dyke, S. J., Ramirez, J., Choi, J. B., Valencia, G., & Alcocer, S. M.** (2024). Building pose detection for the characterization of reinforced concrete buildings. *Structural Design of Tall and Special Buildings*, 33(13). doi:10.1002/tal.2120.
- Karim, S., Zhang, Y., Yin, S., Bibi, I., & Brohi, A. A.** (2020). A brief review and challenges of object detection in optical remote sensing imagery. *Multiagent and Grid Systems*, 16(3), 227–243. doi:10.3233/MGS-200330.
- Kashani, M. M.** (2024). Inelastic buckling of reinforcing bars: A state-of-the-art review of existing models and opportunities for future research. *Construction and Building Materials*, 411. doi:10.1016/j.conbuildmat.2023.134634.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 84–90. doi:10.1145/3065386.

- Kunnath, S. K., Heo, Y., & Mohle, J. F.** (2009). Nonlinear uniaxial material model for reinforcing steel bars. *Journal of Structural Engineering*, 135(4), 335–343. doi:10.1061/(ASCE)0733-9445(2009)135:4(335).
- Lee, B. Y., Kim, Y. Y., Yi, S. T., & Kim, J. K.** (2013). Automated image processing technique for detecting and analysing concrete surface cracks. *Structure and Infrastructure Engineering*, 9, 567–577. doi:10.1080/15732479.2011.593891.
- Lee, Y., Kim, H., Min, S., Yoon, H.** (2023). Structural damage detection using deep learning and FE model updating techniques. *Scientific Reports*, 13, 18694. doi:10.1038/s41598-023-46141-9.
- Lehman, D., Moehle, J., Mahin, S., Calderone, A., & Henry, L.** (2004). Experimental evaluation of the seismic performance of reinforced concrete bridge columns. *Journal of Structural Engineering*, 130(6), 869–879. doi:10.1061/(ASCE)0733-9445(2004)130:6(869).
- Liu, X., Iturburu, L., Dyke, S. J., Lenjani, A., Ramirez, J., & Zhang, X.** (2022). Information fusion to automatically classify post-event building damage state. *Engineering Structures*, 253. doi:10.1016/j.engstruct.2021.113765.
- Mai, P. M., Aspiotis, T., Aquib, T. A., Cano, E. V., Castro-Cruz, D., Espindola-Carmona, A., Li, B., Li, X., Liu, J., Matrau, R., Nobile, A., Palgunadi, K. H., Ribot, M., Parisi, L., Suhendi, C., Tang, Y., Yalcin, B., Avşar, U., Klinger, Y., & Jónsson, S.** (2023). The destructive earthquake doublet of 6 February 2023 in South-Central Türkiye and Northwestern Syria: Initial observations and analyses. *Seismic Record*, 3, 105–115. doi:10.1785/0320230007.
- Massone, L. M., & Moroder, D.** (2009). Buckling modeling of reinforcing bars with imperfections. *Engineering Structures*, 31, 758–767. doi:10.1016/j.engstruct.2008.11.019.
- McKee, C., Sideris, P., & Hubler, M.** (2023). A macromechanical constitutive model for rebar buckling. *Journal of Structural Engineering*, 149. doi:10.1061/JSEMDH.STENG-11349.
- Monti, G., & Nuti, C.** (1992). Nonlinear cyclic behavior of reinforcing bars including buckling. *Journal of Structural Engineering*, 118(12), 3268–3284. doi:10.1061/(ASCE)0733-9445(1992)118:12(3268).
- Moyer, M. J., & Kowalsky, M. J.** (2003). Influence of tension strain on buckling of reinforcement in concrete columns. *ACI Structural Journal*, 100(1), 75–85.
- Murray, J. A., & Sasani, M.** (2017). Seismic hybrid simulation of a nonductile RC building with severe damage to multiple columns. *Earthquake Engineering and Structural Dynamics*, 46(5), 733–752. doi:10.1002/eqe.2828.
- O’Byrne, M., Ghosh, B., Schoefs, F., & Pakrashi, V.** (2014). Regionally enhanced multiphase segmentation technique for damaged surfaces. *Computer-Aided Civil and Infrastructure Engineering*, 29, 644–658. doi:10.1111/mice.12098.

- O’Byrne, M., Schoefs, F., Ghosh, B., & Pakrashi, V.** (2013). Texture analysis based damage detection of ageing infrastructural elements. *Computer-Aided Civil and Infrastructure Engineering*, 28, 162–177. doi:10.1111/j.1467-8667.2012.00790.x.
- Paultre, P., Légeron, F., & Mongeau, D.** (2001). Influence of concrete strength and transverse reinforcement yield strength on behavior of high-strength concrete columns. *ACI Structural Journal*, 98(4), 490–501.
- Ren, S., He, K., Girshick, R., & Sun, J.** (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 2015-Janua, 91–99.
- Sagiroglu, S., & Sasani, M.** (2014). Progressive collapse-resisting mechanisms of reinforced concrete structures and effects of initial damage locations. *Journal of Structural Engineering*, 140(3). doi:10.1061/(ASCE)ST.1943-541X.0000854.
- Shimada, M., Mita, A., & Feng, M. Q.** (2006). Damage detection of structures using support vector machines under various boundary conditions. *Proceedings of SPIE - The International Society for Optical Engineering*, 6174 II. doi:10.1117/12.658956.
- Sinha, S. K., & Fieguth, P. W.** (2006). Automated detection of cracks in buried concrete pipe images. *Automation in Construction*, 15, 58–72. doi:10.1016/j.autcon.2005.02.006.
- Su, J., Wang, J., Bai, Z., Wang, W., & Zhao, D.** (2015). Influence of reinforcement buckling on the seismic performance of reinforced concrete columns. *Engineering Structures*, 103, 174–188. doi:10.1016/j.engstruct.2015.09.007.
- Syntzirma, D. V., Pantazopoulou, S. J., & Aschheim, M.** (2010). Load-history effects on deformation capacity of flexural members limited by bar buckling. *Journal of Structural Engineering*, 136(1), 1–11. doi:10.1061/(ASCE)ST.1943-541X.0000088.
- Tripathi, M., Dhakal, R. P., & Dashti, F.** (2019). Bar buckling in ductile RC walls with different boundary zone detailing: Experimental investigation. *Engineering Structures*, 198. doi:10.1016/j.engstruct.2019.109544.
- Tripathi, M., Dhakal, R. P., Dashti, F., & Massone, L. M.** (2018). Low-cycle fatigue behaviour of reinforcing bars including the effect of inelastic buckling. *Construction and Building Materials*, 190, 1226–1235. doi:10.1016/j.conbuildmat.2018.09.192.
- Tung, P. C., Hwang, Y. R., & Wu, M. C.** (2002). The development of a mobile manipulator imaging system for bridge crack inspection. *Automation in Construction*, 11, 717–729. doi:10.1016/S0926-5805(02)00012-2.
- Ultralytics.** (2023). YOLOv8 documentation. Erişim adresi: <https://docs.ultralytics.com/models/yolov8/>
- Urmson, C. R., & Mander, J. B.** (2012). Local buckling analysis of longitudinal reinforcing bars. *Journal of Structural Engineering*, 138(1), 62–71. doi:10.1061/(ASCE)ST.1943-541X.0000414.

- Yao, G., Sun, Y., Wong, M., & Lv, X.** (2021). A real-time detection method for concrete surface cracks based on improved YOLOv4. *Symmetry*, 13. doi:10.3390/sym13091716.
- Yao, G., Zhu, S., Zhang, L., & Qi, M.** (2024). HP-YOLOv8: High-precision small object detection algorithm for remote sensing images. *Sensors*, 24. doi:10.3390/s24154858.
- Yaseen, M.** (2024). What is YOLOv8: An in-depth exploration of the internal features of the next-generation object detector. *Sensors*, 24. (DOI belirtilmemişse eklenmeli.)
- Yu, S. N., Jang, J. H., & Han, C. S.** (2007). Auto inspection system using a mobile robot for detecting concrete cracks in a tunnel. *Automation in Construction*, 16, 255–261. doi:10.1016/j.autcon.2006.05.003.
- Zhang, C., Chang, C.-C., & Jamshidi, M.** (2020). Concrete bridge surface damage detection using a single-stage detector. *Computer-Aided Civil and Infrastructure Engineering*, 35(4), 389–409. doi:10.1111/mice.12500.



ÖZGEÇMİŞ

Ad-Soyad : Bahadır GÜLEŞMEN

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Yıldız Teknik Üniversitesi, İnşaat Fakültesi, İnşaat Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- Prota Mühendislik (07/2022-05/2023) Yapısal Çelik Tasarım Mühendisi
- Tekfen Mühendislik (05/2023-10/2023) Yapısal Tasarım Mühendisi
- İstanbul Kültür Üniversitesi (10/2023-Halen) Araştırma Görevlisi

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

Gulesmen B. ve Turan O. T. (2025). Detection of Longitudinal Reinforcement Buckling in Reinforced Concrete Columns by a Deep Learning Method, 4th International Graduate Research Symposium. IGRS'25. Istanbul Technical University