



**HAVAALANLARI KAPLAMALI SAHALARINDA  
OLUŞAN YÜZEY KUSURLARININ DERİN  
ÖĞRENME İLE TESPİT EDİLMESİ**

**Yasin YILDIRIM**

**Danışman: Dr. Öğr. Üyesi Nuriye KABAKUŞ**

**Yüksek Lisans Tezi**

**İnşaat Mühendisliği Ana Bilim Dalı**

**2025**

(Her hakkı saklıdır.)

T.C.  
ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

**HAVAALANLARI KAPLAMALI SAHALARINDA OLUŞAN YÜZEY  
KUSURLARININ DERİN ÖĞRENME İLE TESPİT EDİLMESİ**

(Detection of Surface Defects on Paved Areas of Airports With Deep Learning)

YÜKSEK LİSANS TEZİ

Yasin YILDIRIM

Danışman: Dr. Öğr. Üyesi Nuriye KABAKUŞ

Erzurum  
Eylül, 2025



**FEN BİLİMLERİ ENSTİTÜSÜ**  
Graduate School of Natural and  
Applied Sciences

**T.C.**  
**ATATÜRK ÜNİVERSİTESİ**  
**Fen Bilimleri Enstitüsü Müdürlüğü**  
**TEZ KABUL VE ONAY TUTANAĞI**

**HAVAALANLARI KAPLAMALI SAHALARINDA OLUŞAN YÜZEY KUSURLARININ  
DERİN ÖĞRENME İLE TESPİT EDİLMESİ**

Dr. Öğr. Üyesi Nuriye KABAKUŞ danışmanlığında, Yasin YILDIRIM tarafından hazırlanan bu çalışma, 29/08/2025 tarihinde aşağıdaki jüri tarafından İnşaat Mühendisliği Anabilim Dalı Ulaştırma Bilim Dalı'nda yüksek lisans tezi olarak **oybirliği / oy çokluğu (.../...)** ile kabul edilmiştir.

Jüri Başkanı: Prof.Dr. Ahmet TORTUM

Aslı ıslak imzalıdır

*Atatürk Üniversitesi*

Danışman: Dr. Öğr. Üyesi Nuriye KABAKUŞ

Aslı ıslak imzalıdır

*Atatürk Üniversitesi*

Jüri Üyesi: Dr. Öğr. Üyesi Ömer KAYA

Aslı ıslak imzalıdır

*Erzurum Teknik Üniversitesi*

Enstitü Yönetim  
Kurulunun .... / ... / .... tarih  
ve ..... sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Aslı ıslak imzalıdır

**Prof.Dr. Alper NUHOĞLU**

**Enstitü Müdürü**

## ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Dr. Öğr. Üyesi Nuriye KABAKUŞ danışmanlığında sunulan “Havaalanları Kaplamalı Sahalarında Oluşan Yüzey Kusurlarının Derin Öğrenme ile Tespit Edilmesi” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

| Tez Bölümleri                   | Tezin Benzerlik Oranı (%) | Maksimum Oran (%) |
|---------------------------------|---------------------------|-------------------|
| Giriş                           | 2                         | 30                |
| Kuramsal Temeller               | 3                         | 30                |
| Materyal ve Metot               | 7                         | 35                |
| Araştırma Bulguları ve Tartışma | 2                         | 20                |
| Sonuçlar                        | 0                         | 20                |
| Tezin Geneli                    | 4                         | 25                |

**Not:** Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

| Tez Yazarı (Öğrenci)      | Tez Danışmanı                 |
|---------------------------|-------------------------------|
| Yasin YILDIRIM            | Dr. Öğr. Üyesi Nuriye KABAKUŞ |
| 29.8.2025                 | 29.8.2025                     |
| İmza:Aslı ıslak imzalıdır | İmza: Aslı ıslak imzalıdır    |

\* Tez ile ilgili YÖKTEZ'de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun ....../....../.... tarih ve ..... sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun ....../....../.... tarih ve ..... sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

## TEŞEKKÜR

Yüksek lisans serüvenimde ve tezin hazırlanmasında bana her daim destek olan öncelikle aileme, en az benim kadar emek ve mesai harcayan çok değerli danışmanım Dr. Öğr. Üyesi Nuriye KABAKUŞ'a, eğitim sürecinde, araştırmalarımda ve tezin hazırlanmasında çok büyük katkısı olan Doç.Dr. İlhan Volkan ÖNER'e, görüntü işleme uygulamalarında engin tecrübesinden istifade ettiğim Prof. Dr. İlker TÜRKER'e minnet ve şükranlarımı saygılarımla arz ederim.

Yasin YILDIRIM



## ÖZET

### YÜKSEK LİSANS TEZİ

#### HAVAALANLARI KAPLAMALI SAHALARINDA OLUŞAN YÜZEY KUSURLARININ DERİN ÖĞRENME İLE TESPİT EDİLMESİ

Yasin YILDIRIM

Danışman: Dr. Öğr. Üyesi Nuriye KABAKUŞ

**Amaç:** Bu çalışmanın amacı, havaalanı pist, apron ve taksi yollarında meydana gelen yüzey çatlakları vb. deformasyonların, yapay zeka tabanlı derin öğrenme modeli YOLOv11 kullanılarak hızlı, doğru ve otomatik bir şekilde tespit edilmesini sağlamaktır. Böylece, geleneksel manuel inceleme yöntemlerinde görülen zaman kaybı, yüksek hata oranı ve öznellik gibi sorunlara alternatif bir çözüm geliştirilmesi hedeflenmiştir.

**Yöntem:** Çalışmada Türkiye'nin farklı havaalanlarından elde edilen 1000 adet görüntü (650 hasarsız, 350 hasarlı) ile veri tabanı oluşturulmuştur. Görüntüler iPhone 11 cihazı ile fotoğraflanmıştır. Veriler ön işlemten geçirilerek YOLOv11 mimarisiyle eğitilmiş ve test edilmiştir. Model performansı mAP, IoU, precision-recall gibi değerlendirme parametreleri kullanılarak değerlendirilmiştir.

**Bulgular:** Elde edilen sonuçlar, YOLOv11 tabanlı modelin gerçek saha koşullarında yüksek doğruluk ve güvenilirlik ile çatlak ve yama deformasyon tespitini yapabildiğini göstermiştir. Model, sınırlı sayıda ancak çeşitli yapıya sahip veri ile eğitilmesine rağmen pratik uygulamalarda başarılı performans sergilemiştir.

**Sonuç:** Geliştirilen derin öğrenme tabanlı sistem, havaalanı kaplamalı saha yönetiminde bakım-onarım süreçlerinin dijitalleşmesine katkı sağlayarak, uçuş güvenliğini artırmakta ve işlevsel maliyetlerin düşürülmesine olanak tanımaktadır. Çalışma, gelecekte gerçek zamanlı denetim sistemleri, geniş veri setleriyle model iyileştirme ve entegre bakım yönetimi uygulamaları için temel oluşturacak niteliktedir.

**Anahtar Kelimeler:** yapay zeka, derin öğrenme, YOLOv11, havaalanı kaplamalı saha, çatlak tespiti, bakım yönetimi.

Eylül 2025, 126 sayfa

## ABSTRACT

### MASTER THESIS

#### DETECTION OF SURFACE DEFECTS IN PAVED AREAS OF AIRPORTS USING DEEP LEARNING

Yasin YILDIRIM

Supervisor: Dr. Öğr. Üyesi Nuriye KABAKUŞ

**Purpose:** The aim of this study is to provide fast, accurate and automatic detection of surface cracks and deformations on airport runways, aprons and taxiways, using the artificial intelligence based on deep learning model YOLOv11. Thus, it is aimed to develop an alternative solution to the problems such as time loss, margin of error and subjectivity, caused by traditional manual inspection methods.

**Method:** In this study, a database was created with 1000 images (650 undamaged and 350 damaged), obtained from different airports in Türkiye. The images were photographed with iPhone 11. The data was preprocessed, trained, and tested with the YOLOv11 architecture. Model performance was evaluated using metrics such as mAP, IoU, and precision-recall.

**Findings:** The results show that the YOLOv11-based model is capable of crack and deformation detection with high accuracy and reliability under real field conditions. The model performed well in practical applications despite being trained with a limited number of data with diverse structure.

**Results:** The developed deep learning-based system contributes to the digitalization of maintenance and repair processes in airport paved area management, increasing flight safety and reducing operational costs. The study lays the foundation for future real-time inspection systems, model improvement with large data sets and integrated maintenance management applications.

**Keywords:** artificial intelligence, deep learning, YOLOv11, airport paved area, crack detection, maintenance management.

September 2025, 126 pages

## İÇİNDEKİLER

|                                                                     |     |
|---------------------------------------------------------------------|-----|
| KABUL VE ONAY TUTANAĞI.....                                         | i   |
| ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU .....                          | ii  |
| TEŞEKKÜR .....                                                      | iii |
| ÖZET .....                                                          | iv  |
| ABSTRACT .....                                                      | v   |
| TABLolar DİZİNİ.....                                                | ix  |
| ŞEKİLLER DİZİNİ .....                                               | x   |
| KISALTMALAR DİZİNİ .....                                            | xii |
| GİRİŞ.....                                                          | 1   |
| KURAMSAL TEMELLER.....                                              | 3   |
| Hava Ulaşımı ve Havaalanı Mühendisliği .....                        | 4   |
| Ülkemizde Havacılık.....                                            | 4   |
| Havaalanı tesisleri .....                                           | 10  |
| Havaalanı kaplamalı sahaları .....                                  | 10  |
| Havaalanı kaplamalı saha tasarımı .....                             | 12  |
| Kaplamalı saha türleri .....                                        | 14  |
| Havaalanı kaplamalı saha tasarım aşamaları.....                     | 14  |
| Havaalanı üstyapı tasarım yöntemleri .....                          | 18  |
| Havaalanı kaplamaları yüzey şartları .....                          | 20  |
| Kaplamalı sahalarda sürtünme faktörü.....                           | 20  |
| Yüzey sürtünme seviyesinin belirlenmesi.....                        | 22  |
| Makro ve mikro pürüzlülük tanımı ve ölçüm yöntemleri .....          | 22  |
| Frenleme performansı, su birikimi ve aquaplaning riski .....        | 22  |
| Uluslararası havacılık otoritelerinin yüzey dokusu kriterleri ..... | 23  |
| Yüzey pürüzlülüğünün ölçülmesi ve değerlendirilmesi.....            | 24  |
| Kaplamalı saha yüzey temizliği .....                                | 25  |
| Kaplamalı saha yüzey konfor özellikleri.....                        | 25  |
| Havaalanları yüzey kusurları oluşma nedenleri .....                 | 27  |
| Kaplamalı sahalarda gözlenen yüzey kusurları .....                  | 28  |
| Esnek kaplamalarda meydana gelen kusurlar .....                     | 29  |
| Dalgalanmalar ondülasyonlar, ötelenmeler ve yorulma hasarları.....  | 31  |

|                                                                                   |            |
|-----------------------------------------------------------------------------------|------------|
| Lokal oturmlar .....                                                              | 31         |
| Çatlaklar .....                                                                   | 31         |
| Rijit kaplamalarda meydana gelen kusurlar .....                                   | 38         |
| Havaalanı kaplamalarında meydana gelen yüzey kusurlarının tespit yöntemleri ..... | 44         |
| Yüzey deformasyonlarının tespiti .....                                            | 51         |
| Çökme ve dalgalanmaların belirlenmesi .....                                       | 51         |
| Yolun drenaj ve su birikintisi sorunları .....                                    | 52         |
| Aşınma ve malzeme bozulmalarının tespiti .....                                    | 52         |
| Kapsamlı 3D haritalama ve veri analizi .....                                      | 52         |
| <b>MATERYAL VE METOD .....</b>                                                    | <b>60</b>  |
| Materyal .....                                                                    | 60         |
| Metot .....                                                                       | 60         |
| Mimari yenilikler ve temel yapı .....                                             | 61         |
| Parametre verimliliği, hız ve maliyet .....                                       | 62         |
| Görev çeşitliliği ve esneklik .....                                               | 62         |
| Doğrudan performans karşılaştırmaları .....                                       | 62         |
| Makine öğrenmesi .....                                                            | 62         |
| Derin öğrenme (Deep learning) .....                                               | 64         |
| Derin öğrenmenin kullanım alanları .....                                          | 69         |
| Derin öğrenme ile görüntü analizi .....                                           | 74         |
| Evrişimsel sinir ağları (ESA) .....                                               | 77         |
| Evrişimsel sinir ağları (CNN temel bileşenleri) .....                             | 78         |
| Evrişimsel sinir ağları ile görüntü analizi .....                                 | 80         |
| YOLO algoritması .....                                                            | 82         |
| <b>ARAŞTIRMA BULGULARI .....</b>                                                  | <b>83</b>  |
| Görüntü İşlemede Kullanılan Ön İşleme Teknikleri .....                            | 83         |
| Model Eğitimi .....                                                               | 84         |
| Veri Seti .....                                                                   | 85         |
| Etiketleme .....                                                                  | 88         |
| Eğitim parametreleri .....                                                        | 89         |
| Eğitim Sonuçları ve Değerlendirme .....                                           | 90         |
| Genelleme yeteneği ve mAP analizi .....                                           | 96         |
| YOLOv11 algoritmasının diğer modellerle karşılaştırılması .....                   | 97         |
| <b>SONUÇLAR VE ÖNERİLER .....</b>                                                 | <b>100</b> |
| Öneriler .....                                                                    | 102        |

|                |     |
|----------------|-----|
| KAYNAKLAR..... | 104 |
| ÖZGEÇMİŞ.....  | 111 |



## TABLÖLAR DİZİNİ

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| <b>Tablo 1.</b> Ülkemizde Bulunan Sivil Trafığe Açık Olan Hava Alanları.....               | 5  |
| <b>Tablo 2.</b> Ülkemizde Yıllara Göre Oluşan Uçuş Trafığı ve Yolcu Sayıları Tablosu ..... | 8  |
| <b>Tablo 3.</b> Deformasyon-Oluşma Nedeni Tablosu .....                                    | 37 |
| <b>Tablo 4.</b> Derin Öğrenme ile Makine Öğrenmesi Arasındaki Temel Farklar .....          | 67 |
| <b>Tablo 5.</b> Başarı Oranları.....                                                       | 93 |
| <b>Tablo 6.</b> Modellerin Başarı Oranları.....                                            | 98 |
| <b>Tablo 7.</b> Modellerin Performans Tablosu .....                                        | 98 |



## ŞEKİLLER DİZİNİ

|                                                                                   |    |
|-----------------------------------------------------------------------------------|----|
| Şekil 1. İstanbul Yeni Havalimanı hava fotoğrafı .....                            | 6  |
| Şekil 2. Ankara Esenboğa Havalimanı hava fotoğrafı .....                          | 7  |
| Şekil 3. Ordu-Giresun Havalimanı hava fotoğrafı .....                             | 7  |
| Şekil 4. Türkiye’de gerçekleşen yıllara göre yolcu sayısı değişimi grafiği .....  | 9  |
| Şekil 5. Türkiye’de gerçekleşen yıllara göre uçuş trafiği grafiği .....           | 9  |
| Şekil 6. Standart tekerlek ve iniş takımı düzeni konfigürasyonları.....           | 16 |
| Şekil 7. Rijit üstyapı örnek en kesiti.....                                       | 17 |
| Şekil 8. Rijit ve esnek üstyapıda yük dağılımı .....                              | 18 |
| Şekil 9. Yüzey ıslaklığı sürtünme ilişkisi grafikleri .....                       | 21 |
| Şekil 10. Makro ve mikro doku örneklemesi .....                                   | 23 |
| Şekil 11. Yüzey ıslaklığı sürtünme ilişkisi grafikleri.....                       | 23 |
| Şekil 12. Elektronik pürüzlülük ölçme aleti (Elektronik Roughness Indicator)..... | 24 |
| Şekil 13. Pist üzerinde biriken a) Lastik kauçuğu b) Temizliği .....              | 25 |
| Şekil 14. YAMAHA hasarı örnekleri.....                                            | 26 |
| Şekil 15. Tekerlek izinde oturma tipleri.....                                     | 29 |
| Şekil 16. Tekerlek izinde oturma hasarı.....                                      | 30 |
| Şekil 17. Timsah sırtı çatlağı hasarı .....                                       | 32 |
| Şekil 18. Termal çatlak hasarı .....                                              | 32 |
| Şekil 19. Boyuna çatlak hasarı .....                                              | 33 |
| Şekil 20. Blok çatlak hasarı.....                                                 | 33 |
| Şekil 21. Kenar çatlağı hasarı.....                                               | 34 |
| Şekil 22. Yansıma çatlağı hasarı .....                                            | 34 |
| Şekil 23. Asfalt kayması hasarı .....                                             | 34 |
| Şekil 24. Çukur-obruk hasarı.....                                                 | 35 |
| Şekil 25. Cilalanma hasarı.....                                                   | 35 |
| Şekil 26. Asfalt kusması hasarı .....                                             | 36 |
| Şekil 27. Soyulma hasarı.....                                                     | 36 |
| Şekil 28. Rijit üstyapı kaplamasında görülen uzunlamasına çatlak örneği .....     | 38 |
| Şekil 29. Rijit üstyapı kaplamasında görülen köşe çatlağı örneği.....             | 39 |
| Şekil 30. Rijit üstyapı kaplamasında görülen donma çözünme çatlağı örneği.....    | 39 |
| Şekil 31. Rijit üstyapı kaplamasında görülen asr sebepli harita çatlağı .....     | 41 |
| Şekil 32. Kil topağı oyukları .....                                               | 43 |
| Şekil 33. Rijit üstyapıda gözlenen kirlenme örneği .....                          | 44 |

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| Şekil 34. GPR uygulaması örneği .....                                                   | 47 |
| Şekil 35. GPR uygulaması örneği .....                                                   | 48 |
| Şekil 36. Lazer uygulaması örneği .....                                                 | 50 |
| Şekil 37. Multi-laser profilometre ölçüm cihazı çalışma prensibi .....                  | 50 |
| Şekil 38. Line-laser profilometre ölçüm cihazı çalışma prensibi .....                   | 51 |
| Şekil 39. Profilometre ölçüm cihazı .....                                               | 51 |
| Şekil 40. YOLO Versiyonlarının COCO veri kümesi üzerinden karşılaştırması .....         | 61 |
| Şekil 41. Yapay zeka gelişmelerinin tarihsel ilerleyişi .....                           | 63 |
| Şekil 42. Yapay sinir ağı .....                                                         | 65 |
| Şekil 43. Derin öğrenme ile makine öğrenmesi arasındaki temel farklar .....             | 68 |
| Şekil 44. Evrimsel sinir ağı genel mimarisi .....                                       | 68 |
| Şekil 45. Chroma GAN kullanılarak tarihi siyah beyaz fotoğrafların renklendirmesi ..... | 70 |
| Şekil 46. DropOut katmanı uygulaması .....                                              | 79 |
| Şekil 47. CNN mimari yapısı .....                                                       | 79 |
| Şekil 48. YOLO algoritması çalışma prensibi .....                                       | 82 |
| Şekil 49. Veri artırımı metoduyla üretilen görseller .....                              | 84 |
| Şekil 50. Hasarlı yüzeye ait veri seti örnekleri .....                                  | 86 |
| Şekil 51. Sağlam yüzeye ait veri seti örnekleri .....                                   | 87 |
| Şekil 52. Veri etiketleme işlemi .....                                                  | 89 |
| Şekil 53. Model eğitim değerleri .....                                                  | 90 |
| Şekil 54. Eğitim grafikleri .....                                                       | 92 |
| Şekil 55. Precision-recall eğrileri .....                                               | 94 |
| Şekil 56. Recall-confidence eğrileri .....                                              | 94 |
| Şekil 57. Precision-confidence eğrileri .....                                           | 95 |
| Şekil 58. F1-confidence eğrileri .....                                                  | 95 |
| Şekil 59. Test verisi üzerindeki tespitler .....                                        | 96 |
| Şekil 60. Karşılaştırılan modellerin eğitim grafikleri .....                            | 99 |

## KISALTMALAR DİZİNİ

|        |                                                                                   |
|--------|-----------------------------------------------------------------------------------|
| ICAO   | : International Civil Aviation Organization (Uluslararası Sivil Havacılık Örgütü) |
| ABD    | : Amerika Birleşik Devletleri                                                     |
| FAA    | : Federal Aviation Administration (Federal Havacılık Ajansı)                      |
| TOMTAŞ | : Tayyare ve Motor Türk A.Ş.                                                      |
| FOD    | : Foreign Object Damage (YAMAHA-Yabancı Madde Hasarı)                             |
| PAT    | : Pist-Apron-Taksiyolu                                                            |
| RESA   | : Runway End Safety Area (Pist Sonu Emniyet Sahası)                               |
| ARFF   | : Airfield Resque and Fire Fighting (Havalimanı Kurtarma ve Yangınla Mücadele)    |
| EASA   | : European Union Aviation Safety Agency (Avrupa Havacılık Güvenliği Ajansı)       |
| NATO   | : North Atlantic Treaty Organization (Kuzey Atlantik Antlaşması Teşkilatı)        |
| MTOW   | : Maximum Take Off Weight (Maksimum Kalkış Ağırlığı)                              |
| ACN    | : Aircraft Classification Number (Uçak Sınıflandırma Numarası)                    |
| PCN    | : Pavement Classification Number (Kaplama Sınıflandırma Numarası)                 |
| LCN    | : Load Classification Number (Yük Sınıflandırma Numarası)                         |
| PCR    | : Pavement Classification Rating (Kaplama Sınıflandırma Oranı)                    |
| AIP    | : Aeronautical Information Publication (Havacılık Enformasyon Yayını)             |
| USCOE  | : Corps of Engineers                                                              |
| PCA    | : Portland Cement Association                                                     |
| CDOT   | : Canadian Department of Transportation                                           |
| CBR    | : California Bearin Ratio (Kaliforniya Taşıma Oranı)                              |
| ACI    | : American Concrete Institute                                                     |
| CTB    | : Cement Treated Base                                                             |
| CRCB   | : Continuously Reinforced Concrete Base                                           |
| LCG    | : Load Classification Group (Yük Sınıflandırma Grubu)                             |
| ASFT   | : Airport Surface Friction Tester                                                 |
| SARSYS | : Scandinavian Airport and Road Systems                                           |
| ASTM   | : American Society for Testing and Materials                                      |
| TS     | : Türk Standartları                                                               |
| ASR    | : Alkali Silika Reaksiyonu                                                        |

|       |                                                                                     |
|-------|-------------------------------------------------------------------------------------|
| InSAR | : Interferometric Synthetic Aperture Radar (Yapay Açıklıklı Radar İnterferometrisi) |
| GPR   | : Ground Penetrating Radar (Yeraltı Radarı)                                         |
| NDT   | : Non-Destructive Tests (Tahribatsız Testler)                                       |
| TİO   | : Tekerlek İzinde Oturma                                                            |
| IRI   | : International Roughness Index (Uluslararası Pürüzlülük Endeksi)                   |
| YOLO  | : You Only Look Once                                                                |
| DNN   | : Deep Neural Networks (Derin Sinir Ağları)                                         |
| İHA   | : İnsansız Hava Aracı                                                               |
| GPS   | : Global Positioning Sytsem (Küresel Konumlama Sistemi)                             |
| CNN   | : Konvolüsyonel Sinir Ağları (Konvolüsyonel-Evrişimsel Sinir Ağları)                |
| AI    | : Artificial Intelligence (Yapay Zeka)                                              |
| ML    | : Machine Learning (Makine Öğrenmesi)                                               |
| DL    | : Deep Learning (Derin Öğrenme)                                                     |
| YSA   | : Yapay Sinir Ağı                                                                   |
| ESA   | : Evrişimsel Sinir Ağı                                                              |
| RNN   | : Recurrent Neural Networks (Tekrarlayan Sinir Ağları)                              |
| LSTM  | : Long Short-Term Memory (Uzun-Kısa Vadeli Bellek)                                  |
| DBN   | : Deep Belief Network (Derin İnanç Ağları)                                          |
| RBM   | : Restricted Boltzmann Machines (Kısıtlı Boltzmann Makineleri)                      |
| NLP   | : Neuro Linguistic Programming (Doğal Dil İşleme)                                   |
| FSD   | : Full Self Driving (Tam Otomatik Sürüş)                                            |
| ReLU  | : Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)                               |
| VGG   | : Visual Geometry Group (Görsel Geometri Grubu)                                     |
| B-ESA | : Bölgesel Evrişimsel Sinir Ağları                                                  |
| FC    | : Fully Connected (Tam Bağlantılı)                                                  |
| NMS   | : Network Management System                                                         |
| mAP   | : mean Average Precision                                                            |
| IoU   | : Intersection over Union                                                           |

## GİRİŞ

Havacılık sektörü, küresel ölçekte artan yolcu ve yük trafiğiyle birlikte son yıllarda önemli bir büyüme ivmesi yakalamıştır. Bu büyüme, sadece hava araçlarının teknolojik gelişimiyle sınırlı kalmamakta; aynı zamanda havaalanı altyapılarının, özellikle de pist, taksiyolu ve apron gibi kaplamalı saha alanlarının sürekli ve güvenli bir şekilde hizmet verebilir olmasını da gerekli kılmaktadır. Ticari ve askeri havacılık operasyonlarının zamanında, güvenli ve aksamadan gerçekleştirilebilmesi için bu alanların yapısal bütünlüğünün korunması büyük önem taşımaktadır. Zira bu yüzeylerde meydana gelen küçük bir çatlak veya deformasyon dahi, operasyonel aksamaların yanı sıra uçuş güvenliğini ciddi şekilde tehlikeye atabilmekte ve yabancı madde hasarı riski oluşturarak can ve mal kaybına yol açabilmektedir.

Havacılık sektöründe uçuş güvenliği en üst düzeyde tutulması gereken bir önceliktir. Bu bağlamda, havaalanı altyapısında yer alan kaplamalı saha yüzeylerinin düzenli olarak denetlenmesi ve yüzey kusurlarının erken aşamada tespit edilmesi gerekmektedir. Günümüzde yaygın olarak kullanılan manuel denetim yöntemleri, yoğun iş gücü gerektirmesi, uzmanlığa bağımlılığı ve öznel değerlendirmelere açık olması gibi nedenlerle sınırlı bir güvenilirliğe sahiptir. Aynı zamanda, bu yöntemlerin uygulanması zaman alıcıdır ve özellikle geniş yüzey alanlarına sahip havalimanlarında operasyonel verimliliği olumsuz etkilemektedir. Bu nedenle, daha hızlı, doğru, nesnel ve tekrarlanabilir sistemlere olan ihtiyaç her geçen gün artmaktadır.

Son yıllarda dijital teknolojilerin, özellikle de yapay zeka ve derin öğrenme tabanlı sistemlerin, birçok sektörde olduğu gibi havacılıkta da uygulanmaya başlanması, bu alandaki potansiyel problemlere çözüm üretme noktasında umut verici gelişmeler ortaya koymaktadır. Evrişimli Sinir Ağları (CNN – Convolutional Neural Networks) mimarisi, özellikle görüntü verileri üzerinden anlamlı desenleri çıkarma ve sınıflandırma becerisi ile çatlak gibi yüzey kusurlarının tespitinde önemli bir avantaj sağlamaktadır. Bu mimariye dayalı olarak geliştirilen YOLO (You Only Look Once) algoritmaları, nesne tanıma problemlerinde gerçek zamanlı, yüksek doğruluklu sonuçlar sunması nedeniyle literatürde yaygın şekilde kullanılmaktadır. Bu bağlamda, YOLOv11 gibi güncel modellerin havaalanı kaplamalı saha yüzeylerinde kullanılabilirliğinin araştırılması hem bilimsel hem de pratik açıdan önemli katkılar sağlayacaktır.

Havaalanı altyapılarında meydana gelen çatlaklar, genel olarak kaplama malzemesinin yaşlanması, ağır trafik yükü, sıcaklık değişimleri, zayıf drenaj sistemleri veya yapım hataları

gibi nedenlerden kaynaklanmaktadır. Bu çatlakların zamanında tespiti ve onarılması, daha büyük ve maliyetli deformasyonların önüne geçilmesini sağlamaktadır. Bununla birlikte, erken müdahale stratejileri, pistlerin kullanım ömrünü uzatmakta ve işletmecilerin bakım-onarım maliyetlerini minimize etmektedir. Bu noktada, çatlakların otomatik olarak tespit edilmesi amacıyla yapay zeka tabanlı sistemlerin kullanılması hem sürdürülebilirlik hem de güvenlik açısından kritik bir rol oynamaktadır.

Bu çalışmanın temel motivasyonu, mevcut manuel yöntemlerin eksikliklerini giderebilecek, hızlı ve yüksek doğrulukla çalışabilen otomatik bir çatlak tespit sistemi geliştirmektir. Bu kapsamda, Türkiye'deki çeşitli havaalanlarından elde edilen pist, apron ve taksiyolu görüntüleri kullanılarak özel bir veri seti oluşturulmuş ve YOLOv11 algoritması ile eğitilmiş bir derin öğrenme modeli geliştirilmiştir. Veri seti, 650 adet hasarsız ve 350 adet hasarlı görüntüden oluşmakta olup, tüm görüntüler iPhone 11 marka cihazla doğal koşullar altında sahada çekilmiştir. Görüntülerin işlenmesi, boyutlandırılması, etiketlenmesi ve sınıflandırılması süreçlerinde modern görüntü işleme tekniklerinden yararlanılmıştır.

Modelin başarımı, yaygın olarak kullanılan mAP (mean Average Precision), IoU (Intersection over Union), precision-recall gibi metrikler üzerinden test edilmiştir. Ayrıca, modelin saha koşullarında uygulanabilirliği, geleneksel yöntemlerle yapılan denetimlerle karşılaştırılarak analiz edilmiştir. Elde edilen sonuçlar, derin öğrenme tabanlı bu sistemin havaalanı işletmeciliği açısından pratikte kullanılabilirliğini ve güvenilirliğini göstermektedir.

Bu bağlamda çalışma, şu temel hedefleri gerçekleştirmeyi amaçlamaktadır:

- Kaplamalı saha yüzeylerinden elde edilen görüntülerin derin öğrenme yöntemleriyle analiz edilmesi,
- YOLOv11 mimarisinin havaalanı çatlak tespitine uygulanabilirliğinin araştırılması,
- Otomatik çatlak tespiti sisteminin doğruluk performansının belirlenmesi ve manuel yöntemlerle karşılaştırılması,
- Havaalanı işletmeciliği açısından sürdürülebilir, düşük maliyetli ve güvenilir bir bakım-onarım stratejisine katkı sağlanması.

Araştırmanın ortaya koyacağı bulguların, yalnızca Türkiye'deki havaalanlarıyla sınırlı kalmayıp, küresel ölçekte benzer altyapılara sahip sivil ve askeri havalimanları için de yol gösterici olması beklenmektedir. Ayrıca, çalışma sonucunda geliştirilecek olan otomatik sistemin, uçuş güvenliğini artırmasının yanı sıra, bakım süreçlerinin dijitalleştirilmesine ve kaynakların daha verimli kullanılmasına katkı sağlaması hedeflenmektedir. Bu yönüyle araştırma, akademik alana özgün bir katkı sunmakta; aynı zamanda endüstriyel uygulamalara doğrudan entegre edilebilecek nitelikte yenilikçi bir çözüm önerisi sunmaktadır.

## KURAMSAL TEMELLER

Yirmi birinci yüzyılda teknolojik ilerlemelerin baş döndürücü hızda gelişmesi, zaman kavramını toplumsal yaşamda en kıymetli unsurlardan biri haline getirmiştir. Bu durum, özellikle ulaşım ve iletişim sistemlerinin önemini artırmış, bireylerin ve toplumların erişim ihtiyaçlarını karşılamada hava ulaşımını ön plana çıkarmıştır. Hava ulaşımı; hız, konfor ve güvenlik avantajları sayesinde dünya genelinde giderek daha fazla tercih edilmekte, bu da havacılık sektöründe ciddi bir büyüme ve dönüşüme yol açmaktadır. Bu büyümeyle birlikte, havaalanlarının operasyonel verimliliklerinin artırılması ve uçuş güvenliğinin sağlanması için altyapı yatırımları sürekli olarak geliştirilmekte; uçak gövdelerinin büyümesi, taşıma kapasitelerinin artması gibi gelişmeler havaalanlarının daha büyük, teknik olarak daha donanımlı ve sürdürülebilir sistemlerle yeniden yapılandırılmasını zorunlu kılmaktadır.

Havacılık tarihi, insanlığın uçma arzusunun çok eski çağlara dayandığını ve bu arzunun mitolojik anlatılardan günümüz teknolojisine uzanan bir süreci kapsadığını ortaya koymaktadır. İlk uçuş fikrinin izleri Antik Yunan mitolojisinde Daidalos ve İkarus'un balmumu ve kuş tüyünden yaptıkları kanatlarla gerçekleştirdikleri efsanevi kaçış öyküsüne kadar uzanmaktadır (Cartwright,2016). Gerçekleştirilen ilk somut girişimlerden biri ise 9. yüzyılda İbn Firnas'ın kartal tüylerinden yaptığı kanatlarla gerçekleştirdiği uçuş denemesidir (Sığırcı,2025). Benzer şekilde, 10. yüzyılda Cevherî'nin cami minaresinden tahta kanatlarla gerçekleştirdiği atlayış da erken dönem havacılık çabalarının trajik bir örneğidir (Kılıç,1993). Osmanlı döneminde ise 17. yüzyılda Hezarfen Ahmet Çelebi'nin Galata Kulesi'nden Üsküdar'a kadar süzüldüğü uçuşu ve Lâgarî Hasan Çelebi'nin barutla çalışan roketle yükselip denize inişi, havacılık tarihinin ilginç ve dikkat çekici girişimleri arasında yer almaktadır (Sığırcı,2025). Daha sonra Roger Bacon ve Leonardo da Vinci (Kaya vd,2020) gibi bilim insanları aerodinamik prensipler üzerine teorik çalışmalar yapmış, 18. yüzyılda Montgolfier kardeşler ilk balon uçuşunu gerçekleştirmiştir (Kaya vd,2020). 19. yüzyılda Otto Lilienthal'ın gerçekleştirdiği 2000'den fazla planör uçuşu (Öztürk,2021), Wright Kardeşler'in 1903 yılında ilk kontrollü motorlu uçuşu başarımında ilham kaynağı olmuştur (Crouch, 1998). Modern havacılığın bu ilk adımlarını takip eden süreçte, teknolojik gelişmeler savaşlar, ekonomik ihtiyaçlar ve uluslararası düzenlemelerle ivme kazanmış; 1911'de havacılığın savaş aracı olarak kullanılmasıyla birlikte sektör stratejik bir konum elde etmiştir (Güneşen,2003).

## **Hava Ulaşımı ve Havaalanı Mühendisliği**

Havaalanları, uçuş operasyonlarının güvenli ve etkin bir şekilde yürütülebilmesi için yüksek kaliteli pistler, taksi yolları ve apronlardan oluşan kaplamalı sahalara sahiptir. Bu sahaların mühendislik karakteristikleri ve yüzey konforu, Havaalanı Mühendisliğinin en hassas konularındadır.

Uçak teknolojilerindeki hızlı gelişim hem askeri hem de ticari uçuşların sayısını ve kalitesini artırmış, bu çerçevede uçakların kullanmış olduğu altyapıların da yüksek kalitede inşa edilmesi, tesiste uçuş trafiği devam ettiği sürece bakımlı ve hizmete hazır tutulması önem arz etmiştir.

Havaalanı kaplamalı sahalarından farklı kısımlardan işlevlerine göre farklı performanslar beklenmektedir. Örneğin pistte iniş-kalkış ve taksi hareketleri sırasında uçakların frenleme performansı açısından kaymaya karşı iyi bir direnç ve yeterli bir drenaj, teker yüklerinin kaplamaya uyguladığı yüke karşı yeterli dayanım gerekmektedir. Bununla beraber uçuş konforunu etkilemeyecek ve uçakların hassas elektronik cihazlarına zarar vermeyecek yüzey pürüzlülüğü ve kaplama kalitesi havaalanı mühendisliğinin çözmesi gereken problem sahalarındandır. Trafiğin daha yavaş seyrettiği, dinamik ve statik yüklerin ve bu yüklerin meydana getirdiği deformasyonların daha fazla hissedildiği park sahalarında ise ana gereksinim kaplamaya uygulanan yüklerin emniyetle taşınabilmesidir.

Özellikle jet motorlarının kullanımı ile YAMAHA (Yabancı Madde Hasarı) üretmeyecek, yüzey kalitesi bakımından kusursuza yakın PAT (Pist-Apron-Taksiyolu) sahaları inşa edilmeye başlanmış, bu sahaların sürekli trafiğe açık tutulması hava alanı işletmeciliğinin en önemli görevlerinden birisi olmuştur. Çok yüksek maliyetler oluşturan yapım ve bakım operasyonları, çok yüksek bütçelere satın alınan hava taşıtlarının emniyetli bir şekilde görevlerini yerine getirmesi için kritik bir role sahiptir.

## **Ülkemizde Havacılık**

Dünya üzerinde havacılık sektöründe yaşanan gelişmelere ülkemiz hızlı bir reaksiyon göstermiş, Osmanlı İmparatorluğu havacılıkla ilgili ilk resmi girişimini başlatarak Osmanlı Hava Kuvvetleri'ni (Tayyare Bölüğü) yani bugünkü Türk Hava Kuvvetlerini kurmuştur. İlk sivil havacılık faaliyetleri ise 1912 yılında İstanbul Sefaköy'de iki hangar ve küçük bir meydana başlamıştır. 16 Şubat 1925 tarihinde "Türk Tayyare Cemiyeti" ile Türk sivil havacılığının temellerini atılmış, bu kurum sonrasında "Türk Hava Kurumu" adını almıştır (THK, t.y.-a).

İlk yerli uçak (Vecihi K-VI) Vecihi Hürkuş tarafından imal edilmiş ve 28 Ocak 1925 tarihinde ilk uçuş gerçekleştirmiştir (THK, t.y.-b).

1925 yılında Tayyare ve Motor Türk A.Ş. (TOMTAŞ) adı altında bir uçak üretim şirketi kuruldu ve Kayseri’de 6 Ekim 1926 tarihinde uçak üretimine başlandı ve 200 civarında uçak üretildi (THK, t.y.-b).

20 Mayıs 1933 tarih 2186 sayılı Hava Yolları Devlet İşletme İdaresi Teşkilâtı Hakkında Kanunla “Havayolları Devlet İşletme İdaresi” (Bugünkü adıyla Türk Hava Yolları) Millî Savunma Bakanlığı’na bağlı olarak 180.000 TL bütçe, 5 uçak ve 24 personel ile kurulmuş ve Türkiye’de taşımacılık yapmak ve sivil hava yolları kurmak ile görevlendirilmiş, ilk uçuş da İstanbul-Ankara arasında gerçekleşmiştir (THY, t.y.-a).

1943 yılına gelindiğinde Devlet Havayolları tarafından; 36 adet uçak ve 200 personel ile İstanbul, Eskişehir, Ankara, İzmir, Bursa, Elazığ, Erzurum, Kayseri ve Adana Havaalanı olmak üzere 9 havaalanına seferler düzenlenmiştir (DHMI,2021). 12 Şubat 1947 tarihinde ise Devlet Hava Yolları (Türk Hava Yolları) tarafından ilk dış hat uçuşumuz Atina’ya gerçekleştirilmiştir (THY, t.y.-a).

Türkiye’de havacılık sektörü son 20 yılda büyük bir ilerleme kaydetmiş, 2003 yılında 26 adet hava alanı varken bu sayı 2024 yılı itibarıyla 60’a ulaşmıştır (SHGM,2025). Bu hava alanlarının 37’sinde uluslararası uçuşlar gerçekleştirilmektedir. Bu tesislere ilave olarak 18 adet askeri hava üssü sadece Türk Hava Kuvvetleri tarafından kullanılmaktadır.

Türkiye’de sivil hava taşımacılığı faaliyetlerinin yürütüldüğü havaalanlarının sayısal durumu ve ülke genelindeki dağılımı, Tablo 1’de sistematik olarak sunulmuştur.

**Tablo 1.** Ülkemizde Bulunan Sivil Trafığe Açık Olan Hava Alanları (SHGM,2025)

| Sıra | Havaalanı İsmi         | Yapım Yılı | Statü | Pist  | Sıra | Havaalanı İsmi         | Yapım Yılı | Statü | Pist  |
|------|------------------------|------------|-------|-------|------|------------------------|------------|-------|-------|
| 1    | İstanbul Yeni H/A      | 2018       | S     | 5 x E | 32   | Konya H/A              | 2000       | A/S   | 2 x E |
| 2    | Adana Şakirpaşa* H/A   | 1937       | S     | E     | 33   | Malatya H/A            | 1941       | A/S   | 2 x E |
| 3    | Adıyaman H/A           | 1998       | S     | R     | 34   | Mardin H/A             | 1999       | S     | R     |
| 4    | Ağrı Ahmed-i Hani H/A  | 1997       | S     | R     | 35   | Muğla Dalaman H/A      | 1981       | A/S   | R     |
| 5    | Amasya Merzifon H/A    | 2008       | A/S   | 2 x E | 36   | Muğla Milas-Bodrum     | 1998       | A/S   | 2 x R |
| 6    | Ankara Esenboğa H/A    | 1955       | S     | 2 x E | 37   | Muş H/A                | 1992       | A/S   | K     |
| 7    | Antalya H/A            | 1960       | A/S   | E-R-R | 38   | Nevşehir Kapadokya H/A | 1998       | S     | R     |
| 8    | Edremit Koca Seyit H/A | 1997       | S     | R     | 39   | Ordu- Giresun H/A      | 2015       | S     | E     |
| 9    | Balıkesir Merkez H/A   | 1998       | A/S   | E     | 40   | Rize- Artvin H/A       | 2022       | S     | E     |

**Tablo 1. (devamı)**

|    |                                     |      |       |       |    |                               |             |     |       |
|----|-------------------------------------|------|-------|-------|----|-------------------------------|-------------|-----|-------|
| 10 | Batman H/A                          | 1998 | A/S   | E     | 41 | Samsun Çarşamba H/A           | 1998        | S   | R     |
| 11 | Bingöl H/A                          | 2013 | Sivil | R     | 42 | Siirt H/A                     | 1994        | S   | R     |
| 12 | Bursa Yenişehir H/A                 | 2000 | S     | 2 x R | 43 | Sinop H/A                     | 1993        | S   | R     |
| 13 | Çanakkale Gökçeada H/A              | 2010 | S     | R     | 44 | Sivas Nuri Demirağ            | 1957        | S   |       |
| 14 | Çanakkale Gelibolu H/A              | 1995 | A/S   | R     | 45 | Şanlıurfa GAP H/A             | 2007        | S   | R     |
| 15 | Denizli Çardak H/A                  | 1991 | A/S   | E     | 46 | Şırnak Şerafettin Elçi H/A    | 2013        | S   | R     |
| 16 | Diyarbakır H/A                      | 1952 | A/S   | 2 x R | 47 | Çorlu Atatürk H/A             | 1998        | A/S | R     |
| 17 | Elazığ H/A                          | 1940 | A/S   | 2 x R | 48 | Tokat H/A                     | 1995        | S   | R     |
| 18 | Erzincan Yıldırım Akbulut H/A       | 1988 | A/S   | E     | 49 | Trabzon H/A                   | 1957        | S   | E     |
| 19 | Erzurum H/A                         | 1966 | A/S   | E-R   | 50 | Uşak H/A                      | 1998        | A/S | R     |
| 20 | Gaziantep H/A                       | 1976 | S     | R     | 51 | Van Ferit Melen H/A           | 1943        | A/S | E     |
| 21 | Yüksekova Selahaddin Eyyubi H/A     | 2015 | S     | R     | 52 | Sabiha Gökçen H/A             | 2001        | S   | 2 x R |
| 22 | Hatay H/A                           | 2007 | S     | R     | 53 | Gazipaşa-Alanya H/A           | 2009        | S   | R     |
| 23 | Iğdır Şehit Bülent Aydın Havalimanı | 2012 | S     | R     | 54 | Eskişehir Hasan Polatkan      | 1989        | S   | R     |
| 24 | Isparta Süleyman Demirel            | 1997 | S     | R     | 55 | Aydın Çıldır H/A              | 1958        | S   | R     |
| 25 | İstanbul Atatürk H/A *              | 1953 | S     | R-R-E | 56 | İstanbul Hezarfen H/A         | 1992        | S   | E     |
| 26 | İzmir Adnan Menderes H/A            | 1987 | S     | E-R   | 57 | İzmir Selçuk Efes H/A         | 1993        | S   | E     |
| 27 | Kahramanmaraş H/A                   | 1996 | S     | E     | 58 | Zafer H/A                     | 2012        | S   | R     |
| 28 | Kars Harakani H/A                   | 1988 | S     | 2 x E | 59 | Z. Çaycuma H/A                | 1999        | S   | R     |
| 29 | Kastamonu H/A                       | 2013 | S     | E     | 60 | Çukurova H/A                  | 2024        | S   | 2 x R |
| 30 | Kayseri Erkilet H/A                 | 1998 | A/S   | R     | 61 | Bursa Yunuseli H/A Havaalanı* | 1940        | A/  | E     |
| 31 | Kocaeli Cengiz Topel H/A            | 2011 | A/S   | R     | 62 | Sivrihisar Havacılık Merkezi* | <u>2014</u> | S   | E     |

Türkiye'deki önemli havalimanlarına ait mevcut fiziki altyapı ve konum özelliklerini yansıtan hava fotoğrafları sırasıyla Şekil 1'de İstanbul Yeni Havalimanı, Şekil 2'de Ankara Esenboğa Havalimanı ve Şekil 3'te Ordu-Giresun Havalimanı için sunulmuştur.

**Şekil 1. İstanbul Yeni Havalimanı hava fotoğrafı (Köker, 2018)**



**Şekil 2.** Ankara Esenboğa Havalimanı hava fotoğrafı (DHMİ, t.y.-a)



**Şekil 3.** Ordu-Giresun Havalimanı hava fotoğrafı (DHMİ. t.y.-b)

Hava taşımacılığının ülkemizdeki son yıllardaki gelişiminin uçak trafiği bazında analizi yapılacak olursa 2002 yılı uçuş trafiği aralık ayı sonu itibariyle 532.531 iken, bu rakam 2007 yılında 935.567, 2012 yılında 1.376.486, 2017 yılında 1.914.017, 2022 yılı aralık ayı sonu itibariyle 1.885.525 olarak gerçekleşmiştir. 2024 yılında ise bu rakam 2.290.581 toplam uçuş sayısına ulaşmıştır (DHMİ, 2025).


Türk Havacılığının geldiği noktayı bir başka çarpıcı örnekle izah edecek olursak, 2018 yılında hizmete açılan İstanbul Yeni Havaalanı Avrupa'nın en büyük havaalanı olmakla beraber 2022, 2023 ve 2024 yıllarında günlük ortalama 1.401 uçuş ile Avrupa'nın en çok uçuş gerçekleştirilen uluslararası havalimanı olmuştur (SHGM, 2025). Ülkemiz hâlihazırda günlük ortalama 3.140 uçuş ile Avrupa'da 6'ncı sıradadır.

Antalya Havalimanı'nda 03 Ağustos 2024 günü iç hatta 130, dış hatta 1.087 olmak üzere toplamda 1.217 uçak trafiğine hizmet verilerek yeni bir rekora imza atıldı. Antalya Havalimanı'nı 04.08.2024 tarihinde 102.755'i dış hatlar olmak üzere toplam 223 bin 217 yolcu kullanmıştır (Şimşek ve Özdemir Tosun, 2025). Türkiye'de son 22 yılda gerçekleşen uçak trafiği ve yolcu sayıları Tablo 2'de verilmiştir.


**Tablo 2.** Ülkemizde Yıllara Göre Oluşan Uçuş Trafik ve Yolcu Sayıları Tablosu (DHMI, 2025)

| YILLAR | YOLCU TRAFİĞİ |             |                |             | UÇAK TRAFİĞİ |         |            |           |
|--------|---------------|-------------|----------------|-------------|--------------|---------|------------|-----------|
|        | İç Hat        | Dış Hat     | Direkt Transit | Toplam      | İç Hat       | Dış Hat | Overflight | Toplam    |
| 2002   | 8.729.279     | 25.054.613  | 0              | 33.783.892  | 157.953      | 218.626 | 155.952    | 532.531   |
| 2003   | 9.147.439     | 25.296.216  | 0              | 34.443.655  | 156.582      | 218.405 | 154.218    | 529.205   |
| 2004   | 14.460.864    | 30.596.507  | 0              | 45.057.371  | 196.207      | 253.286 | 191.056    | 640.549   |
| 2005   | 20.529.469    | 35.042.957  | 547.046        | 56.119.472  | 265.113      | 286.867 | 206.003    | 757.983   |
| 2006   | 28.774.857    | 32.880.802  | 616.217        | 62.271.876  | 341.262      | 286.139 | 224.774    | 852.175   |
| 2007   | 31.949.341    | 38.347.191  | 418.731        | 70.715.263  | 365.177      | 323.291 | 247.099    | 935.567   |
| 2008   | 35.832.776    | 43.605.513  | 449.091        | 79.887.380  | 385.764      | 356.001 | 269.172    | 1.010.937 |
| 2009   | 41.226.959    | 44.281.549  | 492.835        | 86.001.343  | 419.422      | 369.047 | 277.584    | 1.066.053 |
| 2010   | 50.575.426    | 52.224.966  | 736.121        | 103.536.513 | 497.862      | 421.549 | 293.714    | 1.213.125 |
| 2011   | 58.258.324    | 59.362.145  | 671.531        | 118.292.000 | 579.488      | 462.881 | 292.816    | 1.335.185 |
| 2012   | 64.721.316    | 65.630.304  | 677.896        | 131.029.516 | 600.818      | 492.229 | 283.439    | 1.376.486 |
| 2013   | 76.148.526    | 73.281.895  | 565.447        | 149.995.868 | 682.685      | 541.110 | 281.178    | 1.504.973 |
| 2014   | 85.416.166    | 80.304.068  | 461.105        | 166.181.339 | 754.259      | 591.695 | 333.017    | 1.678.971 |
| 2015   | 97.041.210    | 84.033.321  | 362.473        | 181.437.004 | 832.958      | 623.715 | 358.285    | 1.814.958 |
| 2016   | 102.499.358   | 71.244.179  | 409.609        | 174.153.146 | 886.228      | 566.767 | 376.913    | 1.829.908 |
| 2017   | 109.511.390   | 83.533.953  | 531.501        | 193.576.844 | 909.332      | 591.125 | 413.560    | 1.914.017 |
| 2018   | 112.911.108   | 97.587.056  | 449.475        | 210.947.639 | 892.405      | 651.764 | 473.051    | 2.017.220 |
| 2019   | 99.946.572    | 108.427.124 | 537.642        | 208.911.338 | 839.894      | 716.523 | 478.013    | 2.034.430 |
| 2020   | 49.740.303    | 31.875.837  | 87.545         | 81.703.685  | 572.994      | 280.756 | 201.418    | 1.055.168 |
| 2021   | 68.466.177    | 59.689.585  | 194.460        | 128.350.222 | 738.352      | 466.266 | 262.242    | 1.466.860 |
| 2022   | 78.323.824    | 103.465.515 | 436.192        | 182.225.531 | 786.150      | 702.476 | 394.845    | 1.883.471 |
| 2023   | 90.390.766    | 123.302.397 | 443.412        | 214.136.575 | 869.404      | 816.473 | 485.453    | 2.171.330 |
| 2024   | 95.293.038    | 134.694.726 | 236.847        | 230.224.611 | 902.078      | 866.779 | 521.724    | 2.290.581 |

Türkiye’de son 22 yılda gerçekleşen uçuşlara dair elde edilen verilerle oluşturulan yolcu sayısı değişimi grafiği Şekil 4’te, uçuş trafiğine ait grafik Şekil 5’te sunulmuştur. Özellikle pandemi döneminde yaşanan düşüşler dikkat çekicidir. Hem toplam yolcu sayısının hem de uçak trafiğinin 2023 yılında pandemi öncesi rakamları yakalandığı görülmüştür.



**Şekil 4.** Türkiye’de gerçekleşen yıllara göre yolcu sayısı değişimi grafiği (DHMİ,2025)



**Şekil 5.** Türkiye’de gerçekleşen yıllara göre uçuş trafiği grafiği (DHMİ,2025)

Ülkemizde Türk Hava Kuvvetleri hem de Sivil Havacılık Kurumları ve firmaları uçuş filolarını yenilemiş ve geliştirmiştir. Türk Hava Yolları hem filosunun genişliği hem de uçuş gerçekleştirdiği destinasyonların çeşitliliği bakımından dünyanın en saygın havayolu şirketlerinden birisi haline gelmiştir. Günümüzde Türk Havayolları 2025 yılı itibariyle 490 adet uçağa sahip çok geniş filosuyla (THY, t.y.-c), uzaman uçuş ekipleri ile yurt içi ve dışı dahil olmak üzere 353 farklı noktaya, 131 farklı ülkeye uçuş planlaması yapmaktadır (THY, t.y.-b).

## **Havaalanı tesisleri**

Havaalanı genel tabiriyle hava taşıtlarının yük/yolcu almak ya da bırakmak üzere iniş ve kalkışlarını yaptığı, yolcu ve yükünü aldığı ve boşalttığı, havayolu ile seyahat edecek insanların uçuşlarını beklediği, uçakların uçuş öncesi ve sonrası bakım ve kontrollerinin yapıldığı, yakıt aldığı ve uçuşa hazırlandığı, park alanı olarak kullandığı alanlar bütünü olarak tarif edilebilir. Hava taşıtlarının gelişmesi, hava trafiğinin artması ile hava alanlarının da kapasiteleri ve kaliteleri de bu oranda gelişmiştir. Havaalanı ile açısından iki ana bölümden oluşmakla beraber uçuş hattı ve kara tarafı olarak isimlendirilebilir (Tunç,2003).

Hava tarafında PAT (Pist-Apron-Taksiyolu) Sahaları, aşma /RESA (Runway End Safety Area) Sahaları, yolcu/Yük İndirme Bindirme Alanları, kaza kırım ve yangına müdahale (ARFF) tesisleri, uçuş kontrol kuleleri, yakıt istasyonları, park-ikmal ve bakım hangarları/alanları, pist bakım, onarım, temizliği vb. altyapı destek hizmet birimleri ve benzeri yer operasyonları yürüten birimler bulunmaktadır.

Kara tarafında; yolcu/Yük terminalleri, idari ve güvenlik birimleri, araç park yerleri, tesis içi yollar gibi unsurlar bulunmaktadır.

Bir havaalanı tasarımında hem altyapı mühendisliği hem de üst yapı mühendisliği alanlarında detaylı etüt, araştırma tasarım ve projelendirme aşamalarında ciddi ve uzmanlık isteyen mühendislik hizmetlerine ihtiyaç duyulmaktadır.

Havaalanı kaplamaları, uçakların kalkış, iniş ve manevra yapabilmesi için özel olarak tasarlanmış ve inşa edilmiş yüzeylerdir. Havaalanı kaplamaları, uluslararası standartlar ve düzenlemelere uygun olarak inşa edilmelidir. Bu konuda en önemli kuruluşlar şunlardır:

1. **ICAO** (Uluslararası Sivil Havacılık Örgütü): Havaalanı kaplama standartlarını,
2. **FAA** (Federal Havacılık İdaresi): ABD'deki havaalanları için standartları,
3. **EASA** (Avrupa Havacılık Güvenliği Ajansı): Avrupa'daki havaalanları düzenlemelerini belirler.

Bu kuruluşların belirlediği standartlar kapsamında pist boyutları, eğimi, sürtünme katsayısı, yüzey dayanıklılığı, aydınlatma ve pist işaretleme işleri gibi unsurlar detaylı olarak standardize edilmiştir.

## **Havaalanı kaplamalı sahaları**

Havaalanı kaplamalı sahaları üç ana başlık altında incelenir ve PAT (Pist-Apron-Taksiyolu) olarak isimlendirilir:

### ***Havaalanı pistleri***

Hava taşıtlarının iniş kalkış için kullandığı, yeterli uzunluk-genişlik ve dayanıma sahip kaplamalı özel yüzeyler olarak adlandırılabilir. Havaalanı pistleri tesisi kullanacak uçak tipi ve özellikleri ile pist gereksinimlerini sağlayacak ebatlarda ve dayanımda tasarlanır. Bunun yanı sıra iklim, rakım, hakim rüzgar gibi coğrafi ve meteorolojik koşullar ile drenaj şartları, zemin özellikleri gibi mühendislik problemlerine göre yer seçimi yapılır ve tesis inşa edilir.

Pist uzunluğu, uçak tipine ve havaalanının bulunduğu rakıma ve arazi şartlarına göre değişir:

**Kısa Pistler:** Uzunluğu 1.000-2.000 m arasında inşa edilen ve küçük uçaklar ile bölgesel uçuşlar için tasarlanan tesislerdir.

**Orta Uzunlukta Pistler:** Uzunluğu 2.000-3.500 m arasında inşa edilen ve boyutları çoğu yolcu uçağı için yeterli olan tesislerdir.

**Uzun Pistler:** Uzunluğu 3.500 m ve üzerinde inşa edilen ve boyutları büyük gövdeli ve ağır uçakların (kargo ve uzun mesafeli uçuşlar için) kullanımı için tasarlanan tesislerdir.

### ***Taksiyolu***

Uçakların kalkış/iniş öncesi sonrası pist ile park sahası arasında kat ettiği, pistler ve taksiyolları arasında bağlantıyı sağlayan yollara taksiyolu denilmektedir.

### ***Apron***

Uçakların park yapmak, yakıt almak, bakım işlerini yürütmek, uçuşa hazırlanmak, yolcu ve yük almak/boşaltmak gibi operasyonlar için kullandığı kaplamalı sahalardır.

Havaalanı mühendisliğinde en önemli konulardan birisi uçak trafiğinin cereyan ettiği kaplamalı sahaların, tasarımı, inşası, sonrasında ise bakım ve onarımıdır. Her bir unsur tesisi kullanacak hava taşıtlarının emniyetli bir şekilde uçuş operasyonunun sağlayacak dayanımda ve yüzey şartlarında, uluslararası kriterleri sağlayacak ölçülerde tasarlanması ve inşa edilesi zorunludur.

Havacılık sektöründe uçuş emniyeti kurallara ve Problemi:

Yabancı Madde Hasarı (YAMAHA), hava taşıtına ve hava taşıtının kullandığı yerlere ait olmayan her türlü objeyi kapsar ve güvenli bir uçuş için öncelikle dikkat edilmesi gereken konuların başında gelir.

Yabancı maddeye geliş güzel duran bağlayıcılar/ekipmanlar, uçuş hattında bulunan muhtelif çöpler ve atıklar, bagaj unsurları, lastik kalıntıları, insanlar tarafından düşürülen/atılan

kişisel eşyalar, bakım amacıyla kullanılan teçhizatlar, agrega parçaları, toprak, asfalt/beton parçaları vs. gibi örnekler verilebilir. Özellikle küçük gövdeli jet motoruna sahip savaş uçaklarının kullanmış olduğu kaplamalı sahalarda oluşan YAMAHA'nın motora girmesi jet motorunda çok ciddi ve yüksek maliyetli hasarlara sebebiyet verebilmektedir. Bunun yanı sıra YAMAHA kaynaklı uçak lastiklerinde oluşacak kesikler ve hasarlar iniş ve kalkışlarda büyük sorunlara neden olabileceklerdir.

YAMAHA kaynaklı en büyük uçak kazalarından biri, 25 Temmuz 2000 tarihinde Fransız Havayollarına ait Concorde uçağının yaşadığı kazadır. 113 kişini yaşamını yitirdiği kaza ilk süpersonik jet kazası olarak havacılık tarihindeki yerini almıştır. Araştırmalar, kazanın Concorde uçağından önce havalanan bir uçağın pistte bıraktığı lastik kalıntılarının, Concorde'un kalkış esnasında sol motoruna girerek hasara neden olması sonucu gerçekleştiğini ortaya koymuştur. Uçağın alev alma anı Şekil 9'da sunulmuştur.

Bir başka vaka 3 Kasım 2015 tarihinde Avustralya'da yaşanmıştır. Helikopterde yapılan bakım işlemi akabinde gerçekleştirilen uçuş kontrolünde, helikopterin ana rotor palinde hasar olduğu tespit edilmiştir. Yapılan incelemeler sonucunda titreşim ölçüm cihazının bakımında unutulmuş bakım ekipmanının uçuş sırasında bulunduğu yerden fırlayarak ana rotor palinde hasara neden olduğu anlaşılmıştır (ATSB, 2016).

Görüldüğü üzere YAMAHA çok büyük kayıplara neden olabilecek kaza kırımlarının nedeni olabilmektedir. Bu tür olaylar, en güvenli ulaşım tipi olan hava ulaşımını gerçekleştiren hava araçlarının güvenilirliğini zedeleyebilir, olumsuz bir imaja sebebiyet verebilir.

YAMAHA'nın havacılık firmaları üzerinde doğrudan ve dolaylı olarak isimlendirilen finansal etkileri de bulunmaktadır. YAMAHA kaynaklı hasarları gidermek için planlanan bütçeler doğrudan finansal etkiyi içerir. Uçuş planlamalarında yaşanan aksamalar, gecikmeler ve iptaller ise dolaylı yoldan finansal etki olarak adlandırılabilir. Bu tip hasarların havacılık sektörüne yıllık 4 milyar dolar külfet getirdiği öngörülmektedir (Skybrary, t.y.).

Yukarıda bahsedilen örneklerden anlaşılacağı üzere havaalanı kaplamalı sahalarının, yüksek kaliteli, yeterli dayanıma sahip, temiz ve hasarsız olması çok önemlidir. Dolayısıyla kaplamalı sahalarda oluşan deformasyonların, uçuş emniyetini sekteye uğratmadan, YAMAHA oluşumuna sebep olmadan, herhangi bir hasara neden olmadan tespit edilerek yüzeyin hızlı ve güvenli bir şekilde uçuş trafiğine hazır hale getirilmesi gerekmektedir.

### **Havaalanı kaplamalı saha tasarımı**

Havaalanı ulaşımı, teknolojinin ilerlemesiyle birlikte daha yaygın hale gelmiş, bu da havaalanı kaplamalı sahalarının önemini artırmıştır. Havaalanı kaplamaları veya PAT sahaları,

hava araçlarının yüklerini taşıyıp zemine ileten, kapalı veya açık alanlarda kurulan ve doğal veya düzenlenmiş zemin üzerindeki kaplamaları içeren alanlardır (Kuloğlu vd,2007). Söz konusu alanlar kaplamalı saha olarak adlandırılmaktadır (US Army Corps of Engineers, 2001).

Bir havaalanı kaplamalı sahası komplike bir mühendislik yapısıdır. Kaplamalı saha analizi ve tasarımı dört bileşenin eşit derecede önemli etkileşimini içerir (FAA,1995)

1. Tabi zemin
2. Kaplama materyalleri (yüzey tabakası, temel ve alt temel)
3. Uygulanan yüklerin özellikleri (ağırlık, lastik basıncı, konum ve sıklık),
4. İklim koşulları (yüksek/düşük sıcaklıklar, yağış)

Havaalanı kaplamaları, uçakların kalkış, iniş ve manevra yapabilmesi için özel olarak tasarlanmış ve inşa edilmiş yüzeylerdir ve uçakların uyguladığı aşırı yükleri güvenle tabi zemine aktarması gerekmekte, ayrıca emniyetli kalkış ve duruş için yeterli sürtünmeyi sağlaması beklenmektedir. PAT sahaları şu özelliklere sahip olmalıdır.

1. **Yüksek Taşıma Kapasitesi:** Uçakların ağır yüklerini taşıyabilecek dayanıklılıkta olmalıdır.
2. **Düzgün ve Pürüzsüz Yüzey:** Uçak lastiklerinin aşınmasını en aza indirmek ve güvenli manevra sağlamak için yüzey düzgün olmalıdır.
3. **Sürtünme Direnci:** Yağışlı hava koşullarında kaymayı önlemek için yeterli sürtünme seviyesine sahip olmalıdır.
4. **Dayanıklılık ve Uzun Ömür:** Yoğun hava trafiğine dayanacak şekilde uzun ömürlü olmalıdır.
5. **Drenaj Sistemi:** Yüzeyde su birikmesini önleyecek şekilde tasarlanmış olmalıdır.

Bu sahaların, uçuş trafiğine engel teşkil edecek bozulmalara karşı dayanıklı olması ve uzun yıllar boyunca mevsimsel koşullara mukavim olması beklenmektedir. Havacılık ekipmanlarının maliyeti yüksek olduğu ve güvenlik gereksinimlerinin yüksek seviyede olduğu düşünüldüğünde, kapamalı saha tasarımı sürecinde tüm bu faktörler titizlikle göz önünde bulundurulur. Hesaplanan bir uçak trafiği için performans anlamında beklentileri karşılayacak üstyapı, temel zeminin özelliği, malzeme ve işçilik kalitesi, malzeme karışım oranları ve tabaka kalınlıkları ile doğrudan ilişkilidir. (Ashford,1992),

Havaalanı kaplamalı saha tasarımları uçak teknolojilerinin değişmesi, jet motorlarının kullanımının yaygınlaşması, trafik yoğunluğunun ve dingil yüklerinin artması ile yıllar içinde değişkenlik göstermiş ve gelişmiştir. Uçak gövdelerinin büyümesi, kanat açıklıklarının artması, kullandıkları jet motorlarının daha da güçlenmesi ve sayısının artması ile daha büyük kaplamalı

sahalara, daha uzun ve geniş pist ve taksiyollarına, dayanımı yüksek kaplamalı sahalara ihtiyacı gündeme getirmiştir.

### **Kaplamalı saha türleri**

Havaalanı kaplamalı sahaları genel olarak rijit ve esnek üst yapılar olmak üzere iki farklı teknikle inşa edilmektedir. Rijit kaplamalar çimento bağlayıcılı beton, esnek üst yapılar ise bitümlü karışımlar kullanmak suretiyle yapılan tesislerdir. Pistler ve taksiyolları beton ve asfalt olarak yapılabilmekte, park sahaları genellikle rijit üst yapı olarak tasarlanmaktadır.

Ülkemizde genellikle asfalt pistler karşımıza çıkmakla beraber, özellikle NATO tarafından inşa edilen pistlerimizin beton olduğunu görmekteyiz. Bazı durumlarda üçüncü bir teknik olarak kompozit uygulama da kullanılsa da yeni inşa edilen pistlerden ziyade mevcut bir beton kaplama üzerine esnek üst yapı ilave edilmesiyle yapılan sahalardır.

### **Havaalanı kaplamalı saha tasarım aşamaları**

Havaalanı kaplamalı saha tasarımı sürecini üç ana başlık altında irdelleyebiliriz.

1. Havaalanı arazisinin incelenmesi ve zemin parametrelerinin tayini
2. Uçuş trafiğinin ve yüklerinin tespit edilmesi
3. Üstyapı Tasarımının Yapılması

### ***Havaalanı arazisinin incelenmesi ve zemin parametrelerinin tayini***

Havaalanı arazisinin incelenmesi kaplamalı saha tasarımında çok önemli bir adımdır. Mevcut arazi ve tesislerin durumu, arazinin topoğrafyası, drenaj koşulları, hâkim rüzgâr yönü ve yağış rejimleri gibi meteorolojik veriler, zemin parametreleri gibi pek çok hususun detaylı analiz edilmesi şarttır.

Kaplamalı saha tasarımının en önemli problem sahası; kaplamalı sahanın uygulanacağı zeminin mevcut durumunun doğru bir şekilde analiz edilerek bu zemine en uygun kaplamalı saha tasarımının yapılması, doğru tabaka kalınlıklarının seçilmesi ve tasarlanan tüm üstyapının doğru inşa edilmesidir.

Üstyapı tasarımı doğrultusunda inşa edilecek kaplamalı sahanın tasarımı ile ekonomik ömrü süresince ortaya koyacağı performansı etkileyen en önemli faktörlerden birisi taban zeminin taşıma gücüdür. Taban zemininin taşıma gücünün doğru tespit edilmesi ve üstyapının bu doğrultuda projelendirilmesi kaplamalı saha tasarımında çok önemli bir aşamasıdır.

Hava taşıtları tarafından kaplamalı sahaya uygulana yükler, inşa edilen üstyapı vasıtasıyla iniş takımlarının temas alanından daha büyük bir alan olarak doğal zemine aktarılır

(Özdemir,2010). Kaplamalı sahayı teşkil eden üstyapı kalınlığı ne kadar fazla olursa taban zeminine aktarılabilecek yükün dağıldığı alan o oranda büyük olacaktır. İfadeyi tersten yorumlarsak, tabi zemine iletilen yükün daha büyük bir alana dağıtılabilmesi için zayıf taban zemini üzerinde daha kalın bir üstyapı planlamak suretiyle gerekli sağlamlık seviyesine ulaşılabilir (FAA,1995)

Taban zeminin uygunluğu değerlendirilirken zeminin taşıma gücü, sıkışma kapasitesi, kuru birim hacim ağırlığı, sağlam kayaya/zemine mesafe, yer altı su seviyesi, zayıf zemin tabakalarının mevcudiyeti, don derinliği, zeminin şişme potansiyeli, oturma potansiyeli ve sıvılaşma riski gibi zemine ait parametrelerin belirlenmesi amacıyla detaylı saha ve laboratuvar deneyleri yapılmaktadır.

Yapılacak olan tesisin büyüklüğü ve tecrübeler doğrultusunda yeteri kadar sayıda ve derinlikte sondaj kuyusu açılarak su muhtevası, tabi birim hacim ağırlığı, kuru birim hacim ağırlığı, elek analizi, atterbereg limitleri ve zemin sınıfı tayin edilir. Ayrıca muayene ve gözlem çukurları açılarak zemin numuneleri alınır ve plaka yükleme deneyleri icra edilir.

### ***Uçuş trafiğinin ve yüklerinin tespit edilmesi***

Bu adım kaplamalı sahaya uygulanacak yüklemenin ve ortaya çıkacak gerilmelerin hesaplanması açısından kritik öneme haizdir. Hesaplamalar yapılırken güncel trafik ve uçak bilgilerinin tespit edilmesinin yanı sıra servis ömrü boyunca artması muhtemel trafiğin de dikkate alınması gerekmektedir. Pist ve Taksiyolu gibi tesislerin sonradan genişletilmesi ve taşıma gücünün artırılması teknik açıdan zor ve maliyetli işlemler olması nedeniyle planlamaların ve öngörülerin titiz yapılması çok önemlidir. Dolayısıyla hesaplamalar yapılırken şu üç parametrenin doğru tespit edilmesi gerekmektedir:


- 1. Uçak ağırlığı:** Kaplamalı saha üstyapı kalınlık hesaplamalarında hava taşıtının ağırlığı kritik öneme haizdir. Üstyapı tasarımı çalışmalarında uçağın maksimum kalkış ağırlığı ana unsur olup hesaplamalarda dikkate alınmaktadır. Bu ağırlığın %95'inin uçağa ait ana iniş takımları, %5'inin ise burun bölgesinde bulunan iniş takımı tarafından zemine aktarıldığı değerlendirilmektedir (DLH,2007).
- 2. İniş Takımı Düzeni ve Tekerlek Tipi:** İniş takımları uçağın yer hareketlerini yapmasını, iniş ve kalkışını gerçekleştirmesini sağlar. Uçak tarafından kaplamaya uygulanacak yüklemenin şeklini de ortaya koymaktadır. Genellikle tekerlekli olmakla birlikte iniş yaptığı yüzeye göre suya ya da karlı-buzlu zeminlere iniş imkanı sağlayabilecek özel iniş takımları da görülmektedir. Küçük gövdeli uçaklarda sabit iniş takımları olabilmekle beraber jet motorlu ya da büyük gövdeli

hava taşıtlarında uçağın aerodinamik bütünlüğünü sağlamak adına katlanır iniş takımı kullanılmaktadır.

Uçakların iniş takımlarının yerleştirilmesine göre sınıflandırma yapacak olursak:

- **Kuyruk Tekerlekli İniş Takımı:** Kuyruk tekerlekli iniş takımları, eski tip uçaklarda da yaygın olarak kullanıldığından, literatürde bu yerleşim biçimi genellikle konvansiyonel tip olarak karşımıza çıkmaktadır. Ana iniş takımları, gövde ile kanadın birleşim noktasında ya da kanat altında konumlandırılmış olup, uçağın ağırlık merkezinin biraz önüne monte edilmiştir. Bu nedenle, dengeyi sağlamak ve uçağın arka kısmını desteklemek amacıyla diğer tekerleklerle göre daha küçük olan yardımcı iniş takımı kuyruk bölümüne yerleştirilmiştir.
- **Burun Tekerlekli İniş Takımı:** Jet uçaklarında yaygın olarak kullanılmaktadır. Kuyruk tekerlekli iniş takımlarında yaşanan olumsuzluklar bu tipte giderilmiştir. Konumlandırılmıştır uçağın her kanadının altına, burun iniş takımı ise burun bölümü altında konumlandırılmıştır. Ana iniş takımları uçağın ağırlık merkezinin arkasına, yardımcı iniş takımı ise ağırlık merkezinin önüne planlanmıştır.
- **Tandem İniş Takımı:** İniş takımlarının kanat altına yerleştirilmesini zor olduğu ince uzun ya da kısa kanatlı uçaklarda tercih edilmektedir.

Uçaklarda kullanılan iniş takımları konfigürasyonları Şekil 6’da sunulmuştur.



**Şekil 6.** Standart tekerlek ve iniş takımı düzeni konfigürasyonları (FAA,1995)


3. **Uçak Trafığı:** Bir havaalanı üstyapısını kullanacak hava taşıtlarının yıllık trafik analizlerinin doğru yapılması çok önemlidir. Tesisi kullanacak uçağın fiziksel özelliklerinin yanı sıra üstyapıya uygulanacak tekerrür sayılarının doğru hesaplanması, tasarlanacak olan pist ya da taksiyolunun öngörülen ekonomik ömrünü herhangi bir yapısal deformasyona maruz kalmadan tamamlaması açısından önem arz etmektedir.

## Üstyapı tasarımının yapılması

Üstyapı kalınlıklarının tayini ofis çalışmaları olarak değerlendirilmekle beraber sahadan temin edilen zemin parametreleri ve trafik hesaplamaları doğrultusunda çalışmalar yapılmaktadır.

Bir uçağın bir piste iniş sağlayabilmesi için belli bir dayanıma sahip olması şarttır. LCN (Load Classification Number) /PCN (Pavement Classification Number) /PCR (Pavement Classification Rating) olarak adlandırılan ve AIP’de (Aeronautical Information Publication) yayınlanan değerlere göre bir uçağın bir piste iniş yapıp yapamayacağı belirlenmektedir. ICAO Kasım 2024 itibariyle PCR değeri kullanımına geçmiştir.

Havaalanı PAT sahalarını teşkil eden kaplamalı sahalar, karayolu kaplamalarında oluğu gibi rijit, kompozit ve esnek kaplama olarak sınıflandırılmaktadır. Kaplamalı sahalarla dair tipik kesitler Şekil 7’de sunulmuştur. Rijit üstyapılar portland çimentosu ile üretilen kaliteli beton kaplamalı sahalardır. Esnek üstyapılar bitümlü bağlayıcılarla oluşturulan üstyapı tipidir. Kompozit üstyapılar ise mevcut bir beton kaplama üzerine esnek üstyapı ilavesi ile oluşturulan üstyapılardır.




Şekil 7. Rijit üstyapı örnek en kesiti

Kaliteli beton kaplamalı sahalarda betonun yüksek elastisite modülü ve rijitliğinden dolayı tekrarlı yüklerin büyük bir bölümü geniş bir alana yayılmakta, taşıma kapasitesinin yüksek bir oranını rijit üst yapı sağlamaktadır. Esnek üstyapılarda ise bu durumun aksine yapısal kapasiteyi tüm katmanlar birlikte oluşturmaktadır (Kök,2008).

Karayolu üstyapısı ve havaalanı üstyapısı her ne kadar birbirlerine çok benzer yapılar gibi gözükse de tahmin edileceği karayolları çok daha fazla tekrarlı yüke, havaalanı kaplamaları çok daha büyük yüklere maruz kalmaktadır. Dolayısıyla kaplamayı oluşturan malzemeler benzerlik gösterse de karışım metotları ve oranları, hesaplama prosedürleri farklılıklar arz

etmektedir. Teker yükü altında rijit üst yapıda yük dağılımı Şekil 8-a’da, esnek üst yapıda yük dağılımı Şekil 8-b’de sembolize edilmiştir.



**Şekil 8.** Rijit ve esnek üstyapıda yük dağılımı (Kaşak vd, 2019)

### **Havaalanı üstyapı tasarım yöntemleri**

Havaalanı kaplamalı sahalarında tasarım yöntemlerini hem rijit üstyapılarda hem de esnek üstyapılarda üç ana başlık altında toplayabiliriz. Bunlar ampirik yöntemler, analitik yöntemler ve ampirik-analitik yöntemlerdir.

Ampirik yöntemler saha tecrübelerini ve deney sonuçlarının istatistiksel analizlerini baz alan ve bu doğrultuda tasarımı şekillendiren yöntem biçimi olup süreç uzun ve pahalıdır.

Ampirik-analitik yöntemler, analitik yöntemler kullanılarak direkt olarak modellenemeyen birtakım etkenlerin, performans analizleri ve ampirik bağıntılar yoluyla uyarlanmasını sağlamak amacıyla üretilen yöntemlerdir.

Analitik yöntemler ise; üstyapı tabaka kalınlıklarının kullanılacak olan malzemelerin mekanik özellikleri, tesisin inşa edileceği bölgenin çevresel özellikleri ve tesiste öngörülen trafik yükleri göz önüne alınarak üretilen matematiksel modeller, bu modellerle üretilen abaklar ve çeşitli bilgisayar yazılımları kullanılmak suretiyle tespit edilmesi esasına dayanır.

Havaalanı üstyapı tasarım yöntemlerinin tarihsel geçmişi incelendiğinde Corps of Engineers (USCOE), Portland Cement Association (PCA), Canadian Department of Transportation (CDOT), Federal Aviation Administration (F.A.A.) ve Shell Asfalt Enstitüsü Yöntemleri gibi metotların kullanıldığı görülecektir. Bu yöntemlerin ardından, havaalanı üstyapı tasarımında LCN Yöntemi ve ACN/PCN Yöntemi de kullanılmaya başlanmıştır. Ülkemizde de hem sivil hem de askeri havacılık otoriteleri tarafından LCN, ACN/PCN ve F.A.A. Yöntemlerini kaplamalı saha tasarımında kullanmaktadır (Okur,2008).

- FAA (Federal Aviation Administration) Yöntemi: ABD Federal Havacılık Kurulu (FAA) tarafından geliştirilmiş ve FAARFIELD yazımı kullanılarak tabaka

kalınlıkları hesaplanır. Zeminin California Taşıma Oranı (CBR) değerine kullanılarak tabaka kalınlıkları belirlenir.

- PCA (Portland Cement Association) Yöntemi: Beton kaplamaların tasarımında kullanılır. Beton kalınlığı, yük tekrarı ve eğilme dayanımı baz alınarak hesaplanır
- CBR (California Bearing Ratio) Yöntemi: Zeminin CBR değeri kullanılarak kaplama kalınlıkları belirlenir.

CBR (California Bearing Ratio), zeminin taşıma gücünü belirlemek için kullanılan bir laboratuvar deneyidir. Bu deney, özellikle yol ve havalimanı zeminlerinin tasarımında önemli bir rol oynar. CBR değeri, bir zeminin taşıma gücünü belirlemek için kullanılır ve genellikle yol tabanı tasarımında temel bir parametre olarak kabul edilir. Basitçe ifade etmek gerekirse üniform basınç altında yapılan bir penetrasyon deneyidir. FAA tarafından küçük ve orta ölçekli havaalanları için önerilir. Alt temel ve temel tabaka kalınlıkları CBR grafikleri yardımıyla bulunur.

- ICAO (Uluslararası Sivil Havacılık Örgütü) Yöntemi: Pavement Classification Number (PCN) ve Aircraft Classification Number (ACN) hesaplarına dayanır.  $ACN \leq PCN$  olacak şekilde kaplama tasarlanır.
- ACI (American Concrete Institute) Yöntemleri
- CTB (Cement Treated Base) ve CRCB (Continuously Reinforced Concrete Base) Yöntemleri.

Havaalanı üstyapılarının taşıma kapasitelerinin tespiti günümüzde de en temel problemlerden biri olmakla beraber bu parametrenin tespiti için iki yöntem ortaya konulmuştur. 1956 yılında Uluslararası Sivil Havacılık Organizasyonu (ICAO) tarafından LCN sistemi önerilmiş ve bunun 1965 yılında ikinci baskısı yapılmıştır. Bu yöntem zamanla geliştirilmiş ve ICAO tarafından 1977 yılında LCG (yük sınıflandırma grubu) sistemi yayınlanmıştır (PCA,1966). 1981 yılında, ICAO Ek-14'te uçağın yük oranları ve havaalanı üstyapı kuvvet dayanımının rapor edilmesinde kullanılacak olan uluslararası nitelikli standart ACN/PCN sistemi yayınlanmıştır. Kasım 2024 tarihinde ise PCR sistemine geçilmiştir.

Bir uçağın bir piste iniş sağlayabilmesi için belli bir dayanıma sahip olması şarttır. LCN (Load Classification Number) /PCN (Pavement Classification Number) /PCR (Pavement Classification Rating) olarak adlandırılan ve AIP'de (Aeronautical Information Publication) yayınlanan değerlere göre bir uçağın bir piste iniş yapıp yapamayacağı belirlenmektedir.

### ***Kaplamaların dayanıklılığı ve bakım gereklilikleri***

Bir havaalanı kaplamalı sahasının uçağın emniyetli bir şekilde inişini, kalkışını, park alanına kadar olan kat edişini sağlayacak dayanıma sahip olması zorunludur. Aksi takdirde uçağın bu tesise ulaşımı gerçekleşmez.

Bunun yanı sıra kapamalı sahalardaki bozulmaların ve deformasyonların sık sık kontrol edilerek YAMAHA üretmesine mahal vermeden, herhangi bir kaza kırma sebep olmadan gerekli onarımların yapılması çok önemlidir. Özellikle rijit kaplamalı sahalarda beton kaplama derzlerinin temizliğinin düzeni olarak yapılması, derz dolgu malzemelerinin kontrol edilerek yıpranan bölgelerin yenilenmesi zaruridir.

Bakım işlemleri kapsamında pist yüzeyindeki lastik izi, yakıt ve egzoz kalıntısı, karla mücadele solüsyonu gibi sürtünmeyi zafiyete uğratabilecek kimyasalların temizliği diğer bakım operasyonları kapsamında kritik öneme sahiptir.

### **Havaalanı kaplamaları yüzey şartları**

Uçakların I. Dünya Savaşı'ndaki başarısı ve II. Dünya Savaşı itibariyle hava taşıtlarına jet motorlarının entegrasyonu, hava alanı tesislerinde de pek çok gelişimi ve standartlaşmayı beraberinde getirmiştir. İlk tasarım uçaklar herhangi bir düz alanda iniş kalkış yapabiliyorken, jet motorlu uçaklar yüksek dayanımlı ve kaliteli, belli ölçülere ve kriterlere sahip YAMAHA'dan arındırılmış pistlere ihtiyaç duyarlar.

Jet motorlarının havacılık sektöründe yaygınlaşması ile jet motoruna sahip uçakların da iniş-kalkış, taksi ve park yapacakları alanların da belirli özelliklere sahip olması mecburiyetini doğurmuştur. Bir havaalanı pist kaplaması, iniş, kalkış ve taksi sırasında uçağın neden olacağı trafik yüklerine dayanabilmelidir. Bu kaplamalı saha katmanlarının strüktürü ile ilgili bir durumdur. Havaalanı kaplamalı sahaları uçakların teknolojik ve yapısal hassasiyetleri sebebiyle bir takım yüzey şartlarında sahip olmalıdır. Bu parametre ise kaplamalı sahanın yüzey kondisyonu ile ilgilidir.


### **Kaplamalı sahalarda sürtünme faktörü**

Uluslararası Sivil Havacılık Teşkilatı (ICAO) tarafından yayımlanan Kaplama Yüzey Özellikleri dokümanına göre, bir havaalanı pistinin yeterli sürtünme özelliklerine sahip olması, uçuş güvenliği açısından kritik bir gerekliliktir. Uçaklar iniş yaptıktan veya kalkışın iptal edilmesinin ardından güvenli bir şekilde yavaşlamak için yeterli sürtünmeye ihtiyaç duyar. Ayrıca, özellikle çapraz rüzgârlar, motor gücündeki asimetrik durumlar veya teknik arızalar gibi olası riskler karşısında, kalkış ve iniş esnasında uçağın yön kontrolünün korunması büyük


önem taşır. Bununla birlikte, tekerleklerin piste temas ettiği anda gerekli dönüş hızına ulaşabilmesi de pist yüzeyinin sağladığı sürtünme ile doğrudan ilişkilidir (ICAO,2002). Havaalanı pistlerinde yaşanan pistten çıkma, pisti aşma vb olaylar incelendiğinde yetersiz pist sürtünme özelliklerinin/uçak frenleme performansının çoğu vakada en önemli sebep veya en azından destekleyici husus olduğunu göstermektedir (SHGM,2017).

Sürtünme katsayısı, birbirine temas eden iki yüzey arasında (uçak tekerlek lastikleri ile pist yüzeyi) meydana gelen izafî hareketin sürdürülebilmesi için gereken teğetsel kuvvetin, bu yüzeyleri temas halinde tutan dikey kuvvete (uçak tekerlek lastiği alanına dağılan uçak ağırlığı) oranı olarak tanımlanır. Yunanca  $\mu$  harfi ile gösterilen bu katsayı, yüzeylerin göreceli kayganlığını belirlemek için kullanılan basit bir ölçüm yöntemidir (SHGM,2017).

Kaplamanın fiziki yüzey pürüzlülüğü yanında iniş kalkışta fren mesafelerini ve uçuş emniyetini etkileyen önemli faktörlerden birisi de yüzey ıslaklığı ve yüzey kirleticilerin mevcudiyetidir. Bu sebeple kaplamalı saha projelendirilirken göz önünde bulundurulacak en önemli hususlardan birisi yüzey ve temel drenajıdır. Öncelikle uçuş emniyetini yüzeyin sürtünmesini, dolayısıyla frenleme mesafesini etkileyecek, aynı zamanda kaplamaya ve yapıyı oluşturan katmanlara zarar verecek olan yağmur ve kar suyunun deşarjı çözülmesi gereken önemli bir sorundur.



a



b

**Şekil 9.** Yüzey ıslaklığı sürtünme ilişkisi grafikleri (SHGM,2017)

Şekil 9-a'da ıslak pistte yüzde kayması ile sürtünme arasındaki ilişki gösterilmiştir. Kayma oranı arttıkça sürtünme katsayısı düşmektedir. Optimum sürtünme katsayısı %20 kayma oranında görülmektedir. Şekil 9-b'de ise farklı yüzey şartlarında yanar sürtünme katsayısı ile sapma açısının tipik olarak değişkenlik göstermesi gösterilmiştir.

Yuvarlanma direnci, tekerlek lastiği ve yüzeyin elastik deformasyonu sonucu oluşan sürtünmedir. Konvansiyonel çapraz kuşaklı uçak lastiklerinde, bu direnç dikey yükün yaklaşık %2'si kadar olup, tekerleğin dönmesi için pist ile lastik arasındaki sürtünme katsayısından daha düşük olmalıdır.

## **Yüzey sürtünme seviyesinin belirlenmesi**

Pist yüzeyindeki sürtünme seviyesini belirlemek için Mu-Meter, Skiddometer, Grip Tester, Runway Friction Tester, Surface Friction Tester, ASFT ve SARSYS gibi mekanik-elektronik ölçüm cihazları kullanılmaktadır. Bu cihazlar farklı tasarımlara sahip olmakla birlikte, genellikle bir araçla çekilen veya araca monte edilmiş sürtünme ölçüm tekerlekleri ile çalışır ve pistin her üçte birlik bölümü için frenleme değerlerini elektronik sistemlere kaydeder. Frenleme ölçümleri, özellikle pistin ıslak, su birikintili, kar ya da buzla kaplı olduğu durumlarda gerçekleştirilir. Test süreci, pist eşiğinden başlayarak merkez hattının sağından ilerleyen frenleme ölçüm aracının gidiş-dönüş yapmasıyla tamamlanır.

## **Makro ve mikro pürüzlülük tanımı ve ölçüm yöntemleri**

Pist yüzeyleri fiziksel açıdan değerlendirildiğinde makro ve mikro dokular içermektedir. Mikro doku, yüzeyde 0,05 mm'den küçük genişlikteki düzensizlikleri ifade eder ve agrega taneciklerinin mineralojik yapısına bağlıdır. Makro doku ise 0,05 mm'den büyük genişlikteki ayrılma ve sapmalar olup, kaba agregaların kaplama içerisindeki dağılım şekline bağlıdır (SHGM,2017).

Makro doku, üstyapı serimi sırasında agrega taneleri arasında kalan boşlukların oluşturduğu veya oluk açma gibi yapay yöntemlerle meydana gelen yüzeyin kaba dokusudur. Bu doku, çeşitli yöntemlerle ölçülebilir ve yüzeyle temas eden suyun drenajında önemli bir rol oynar. Mikro doku ise, yüzeyde hissedilebilen ancak doğrudan ölçülmesi mümkün olmayan münferit agrega parçalarından oluşur. Yüzeyin makro doku derinliğini belirlemek için en yaygın kullanılan ve en uygun kabul edilen teknikler gres ve kum yaması yöntemleridir (SHGM,2017).


## **Frenleme performansı, su birikimi ve aquaplaning riski**

Aquaplaning, diğer adıyla hydroplaning veya suda kızaklama, bir aracın yüksek hızda su birikintileri üzerinde kayarak kontrolünü kaybetmesi durumudur. Bu olay, lastiklerle yol yüzeyi arasında ince bir su tabakasının oluşması sonucu meydana gelir ve frenleme ile yol tutuşunu olumsuz etkileyebilir. Yoğun yağış, yüzey bozuklukları, eğim ve yetersiz drenaj gibi faktörler nedeniyle oluşan su birikintileri, lastiklerin altına girerek yol yüzeyiyle temasını keser. Bu durumda, lastikler pist yüzeyine tutunamaz ve uçak suyun üzerinde kayar.

Makro doku, uçak lastiklerinin suda kayma eğilimini azaltarak suyun yüzeyden tahliye edilmesine yardımcı olurken, mikro doku ise ince su tabakalarının yüzeyde dağılmasında önemli bir rol oynar. Hem makro hem de mikro dokuların ıslak zeminde sürtünme katsayısı üzerinde belirgin etkileri olduğu için, yalnızca makro doku ölçümleri kullanılarak ancak genel

eğilimler belirlenebilir. Mevcut veriler, ıslak yüzeylerde daha yüksek sürtünme katsayısı sağlamak için büyük makro dokuların avantajlı olduğunu göstermektedir (SHGM,2017).


Makro ve mikro dokuların yapıları ve kaplamanın hangi bölümünde bulundukları Şekil 10'da görselleştirilmiştir.



**Şekil 10.** Makro ve mikro doku örneklemesi

Kaplama tabakasında kullanılan agregalar, trafik etkisiyle zamanla aşınarak yüzey pürüzlülüğünü kaybeder ve cilalanmış bir hale gelir. Bu durum, kaplamanın kayma direncini azaltarak sürüş güvenliğini olumsuz yönde etkileyebilir. Hem makro hem de mikro dokuların ıslak zemindeki sürtünme katsayısına önemli ölçüde etki etmesi nedeniyle, makro doku ölçümleri yalnızca genel eğilimleri belirlemek için kullanılabilir (SHGM,2017).

Pist yüzeyinde suyun lastik altından etkin şekilde tahliye edilmesini sağlayan yeterli makro doku mevcut olduğunda, sürtünme değeri hız değişimlerinden daha az etkilenir. Buna karşın, düşük makro dokulu yüzeylerde hız arttıkça sürtünme daha fazla azalır. Ayrıca, Şekil 11'de görsel olarak gösterildiği gibi, yüzeyin sürtünme seviyesini belirleyen temel faktörlerden biri de mikro dokunun keskinliğidir (SHGM,2017).



**Şekil 11.** Yüzey ıslaklığı sürtünme ilişkisi grafikleri (SHGM,2017).

### Uluslararası havacılık otoritelerinin yüzey dokusu kriterleri

Yeni inşa edilen bir pist yüzeyinin, ıslak koşullarda yeterli sürtünme performansı sağlayabilmesi için ortalama makro doku derinliğinin en az 1 mm olması önerilmektedir. 1 mm'den daha düşük bir derinlikte dahi etkin drenaj sağlanabilse de standart kaplama kullanımı zamanla yüzeyin bozulmasına yol açabileceğinden, yeni yüzeylerin inşasında bu asgari değerin

üzerinde bir derinlik hedeflenmelidir (SHGM,2017). İnşaat aşamasında, yüzey dokusunun yeterli düzeyde oluşturulmaması durumunda, kısa vadede bakım gerekliliği ortaya çıkabilir. Bu nedenle, yüzey makro dokusunun ölçülmesi ve sürtünme-hız eğrisinin eğimini belirlemek için uygun bir analiz yönteminin uygulanması önem arz etmektedir.

Ortalama makro doku derinliğinin doğru şekilde belirlenebilmesi için yüzeyin tamamını temsil eden örnekler alınmalı ve değerlendirilmelidir. Bu örnekleme sürecinde, yüzey makro dokusunda meydana gelen farklılıklar dikkate alınarak, değişkenliğe bağlı olarak örnek sayısı belirlenmelidir. Ölçümlere başlamadan önce kaplama yüzeyinde belirgin farklılıkları tespit edebilmek adına görsel inceleme yapılması faydalıdır. Genel olarak, yüzey makro dokusunun ölçümünde en güvenilir yöntemler olarak gres ve kum yaması teknikleri kabul edilmektedir (SHGM,2017).

### **Yüzey pürüzlülüğünün ölçülmesi ve değerlendirilmesi**

Pürüzlülükle ilgili dikkat edilmesi gereken önemli bir husus, yüzeydeki pürüzlülük seviyesinin belirli bir sınırın altına düşmemesidir. Uçakların iniş takımlarının zarar görmemesi, elektronik sistemlerin (aviyonik, radar vb.) sarsıntılardan etkilenmemesi, lastiklerde aşırı hasar ve kauçuk kaybı yaşanmaması ile kaplamanın aşırı dinamik yüklerle karşı karşıya kalmaması gibi faktörler, ICAO tarafından yüzey pürüzlülüğüyle ilgili belirli kısıtlamaların getirilmesine neden olmuştur.

Sivil Havacılık Genel Müdürlüğü'nün yayımladığı Havaalanı Emniyet Standartları Talimatı'nda yer alan cetvelde, bir pistin yüzeyinin, sürtünme özelliklerine zarar verebilecek veya bir uçağın kalkış ya da inişini olumsuz etkileyebilecek herhangi bir düzensizlikten arındırılmış olması gerektiği vurgulanmaktadır. Ayrıca, yüzeydeki düzensizliklerin, uçakların kontrolünü zorlaştırarak aşırı zıplama, savrulma, titreme ya da başka mekanik sorunlara yol açabileceği ve bu durumların uçuş güvenliğini tehlikeye atabileceği ifade edilmektedir (SHGM,2017). Ülkemizde yüzey pürüzlülüğü AYGM test ekiplerince Şekil 12'de gösterilen araç ile ölçülmektedir.



**Şekil 12.** Elektronik pürüzlülük ölçme aleti (Elektronic Roughness Indicator)

### **Kaplamalı saha yüzey temizliği**

PAT (Pist, Apron ve Taksiyolu) sahalarında yüzeyde meydana gelen değişiklikler, sürtünme özelliklerini olumsuz yönde etkileyerek güvenlik risklerine yol açabilir. Bu tür değişimlerin giderilmesi, uçuş güvenliği açısından büyük önem taşır. Yüzeyde oluşabilecek yapısal bozukluklar, lastik izleri, çizgiler ve özellikle yakıt, yağlayıcı maddeler ile hidrolik yağlar gibi kirleticiler sürtünme değerini düşüren etkenlerdir. Ayrıca, karla mücadele hizmetlerinde kullanılan kimyasallar ve tuzların etkisi de yüzeyin sürtünme özelliklerini değiştirebilir.

İniş ve kalkış sırasında uçak tekerleklerinden yüzey üzerine bırakılan kauçuklar da sürtünmeyi azaltabilen önemli faktörlerdendir. Pist üzerinde biriken lastik izleri ve egzozdan çıkan ince yağın beton yüzeyine yapışması, pistin kayganlaşmasına neden olabilir. Yağmurun ardından pist yüzeyi daha da kayganlaşarak, küçük bir pilotaj hatasıyla ciddi kazalara yol açabilir. Bu tür olumsuzlukların önlenmesi ve yüzeyin bakımının düzenli yapılması, havaalanı operasyonlarının güvenliğini sağlamada kritik bir rol oynar.

Kaplama yüzeyinde Şekil 13-a'da görüldüğü gibi kalan kauçuk ve zararlı kalıntılar, uzman ekipler tarafından düzenli olarak Şekil 13-b'de gösterilen araç kullanılarak temizlenmektedir. Bu işlem kimyasal çözücüler, yüksek tazyikli su püskürtülmesi ve basınçlı sıcak hava yöntemleri kullanılmak suretiyle yapılır (SHGM,2017).



a



b

**Şekil 13.** Pist üzerinde biriken a) Lastik kauçuğu b) Temizliği (Avcı, 2021)


### **Kaplamalı saha yüzey konfor özellikleri**

Pistler minimum yüzey düzensizliği ile inşa edilmeli ve kaplamanın yük taşıma mukavemeti amaçlanan uçağın tipi ve kütlesi ile diğer faktörlere uygun olmalıdır. Yüzey düzensizlikleri, kalkış ve iniş sırasında aşırı sıçrama, yunuslama ve titreşim ve kontrol edilemezlik yaratarak uçağın çalışmasını olumsuz etkileyebilir. Benzer şekilde, kaplamanın uygun olmayan yük taşıma gücü, pist iniş bölgesinde uçağın güvenliğini tehlikeye atabilecek önemli bir deformasyona neden olabilir. Netice itibarıyla uçakların yer hareketlerini

gerçekleştirdikleri kaplamalı sahalar hem uçağın kaplamaya uyguladığı yüklemeye karşı mukavim olacak, hem emniyetli frenaj ve durmayı sağlayacak belirli sürtünme şartlarını sağlayacak, hem de uçağın mekanik ve elektronik sistemlerine zarar vermeyecek düzgünlükte olacaktır.

Buradaki en kritik huşulardan birisi de jet motorlarının YAMAHA hasarına maruz kalmamasıdır. Jet motorları çalışma esnasında motorun ön kısmındaki hava girişinden dışarıdan hava alır, hava yüksek hızda motora girer ve sıkıştırma aşamasına hazırlanır. Hava, dönen kompresör kanatları tarafından sıkıştırılır ve sıkıştırılan havanın basıncı ve sıcaklığı artar. Sıkıştırılmış hava, yanma odasına girer ve üzerine yakıt püskürtülerek ateşlenir. Yakıtın yanması sonucu yüksek basınçlı ve yüksek sıcaklıklı gazlar oluşur ve bu gazlar türbin kanatlarından geçerek türbini döndürür. Türbin, kompresörün ve diğer yardımcı sistemlerin çalışmasını sağlar. Gazlar, türbinden çıktıktan sonra nozülde yüksek hızla dışarı atılır. Gazların dışarı atılması, motorun ileri doğru itme kuvveti üretmesini sağlar. Buradaki hassas konu jet motorunun çalışması esnasında oluşan yüksek hava emiş gücü kaplamalı saha üzerinde olmaması gereken maddelerin jet motoruna çekilmesine sebep olur ve motorlarda çok büyük hasarlara neden olabilir.

Şekil 13-a'da bir jet motoru hava girişi görülmektedir. Şekil 13-b'de ise YAMAHA kaynaklı blade hasarı gösterilmiştir. Yine Şekil 14-c'de uçak lastiğine saplanan bir madde, Şekil 14-d ve Şekil 14-e'de YAMAHA kaynaklı lastikte oluşan hasar, Şekil 13-f'de ise jet motorunun içine çektiği cisim görülmektedir.



**Şekil 14.** YAMAHA hasarı örnekleri (İGA,2019)

Uçakların bu kadar hassas araçlar olması onarın yer hareketlerini sağlayan tesislerin de çok üst kalitede olması zorunluluğunu doğurmuştur. Bu sebeple PAT sahaları olarak adlandırılan hava alanı kaplamalı sahalarının tasarımı, uygulaması ve bakım-onarımı çok hassasiyet isteyen ve uzmanlık gerektiren bir alan olarak ön plana çıkmaktadır.

### **Havaalanları yüzey kusurları oluşma nedenleri**

Havaalanı kaplamalarının bozulması, çevresel faktörler, havacılık trafiği, malzeme özellikleri ve bakım uygulamalarından etkilenen çok yönlü bir sorundur. Çeşitli çalışmalar bu etkileri belgelemiş ve havaalanı güvenliğini ve işlevsel uzun ömürlülüğü sağlamak için etkili yönetim ve bakım stratejilerine duyulan kritik ihtiyacı vurgulamıştır.

Donma-çözülme döngüleri, iklim koşulları ve buz çözücü kimyasallar gibi çevresel faktörler kaplamanın bozulmasına önemli ölçüde katkıda bulunur. Xu ve arkadaşları, donma-çözülme döngüleri nedeniyle beton dayanıklılığının bozulmasının, kaplama karışımlarında kullanılan lifler arasındaki arayüzey bağına yakından bağlı olduğunu vurgulayarak, seçici işlem süreçlerinin bu tür sorunları azaltabileceğini belirtmiştir (Xu vd., 2022). Ayrıca, yetersiz drenaj yönetimi su sızmasına izin vererek bu sorunları daha da kötüleştirmekte ve kaplama yüzeylerinin daha da bozulmasına yol açmaktadır (Hastings vd., 2022). Etkili drenaj yönetimi, olumsuz hava koşullarıyla ilişkili bozulma risklerini azaltmak için gerekli olan drenaj hususlarını gözden geçiren Hastings ve arkadaşları tarafından belirtildiği gibi, kaplama bütünlüğünü korumak için çok önemlidir (Hastings vd., 2022).

Uçak operasyonlarının getirdiği baskılar üstyapı durumunu daha da karmaşık hale getirmektedir. İniş yapan ve taksi yapan uçaklardan kaynaklanan dinamik yükler, üstyapılarda önemli mekanik stres yaratır ve genellikle çatlama veya yüzeyde yuvarlanma gibi sıkıntılara neden olur (Meng vd., 2024). Bu stresler, çeşitli yük koşulları altında pist performansını değerlendiren çalışmalarda görüldüğü üzere, pistin yapısal kabiliyetlerini zaman içinde azaltabilir (Bao-li vd., 2022). Örneğin, Meng ve arkadaşları, rijit kaplamaların hem statik hem de dinamik yükler altındaki mekanik tepkilerini araştırmak için sonlu elemanlar modellemesini kullanmış ve bu gerilimlerin yüzey bütünlüğü ve uçak güvenliği üzerindeki etkilerine işaret etmiştir (Meng vd., 2023).

Üstyapı bakım stratejileri bu karmaşıklıkları ele alacak şekilde gelişmelidir. Cordovil ve arkadaşları, askeri havaalanlarındaki kaplamaların trafik ve iklim etkileri nedeniyle bozulmasını tartışmış ve devam eden değerlendirmelerin, bakım eylemlerinin planlanması için kritik bir ölçüt olan kaplama durum endeksi (PCI) hakkında değerli bilgiler sağlayabileceğini öne sürmüştür (Cordovil vd., 2022). Benzer şekilde, Wesołowski ve arkadaşları, bozulma

derecesini deęerlendirmek iin ok kriterli bir yaklařımın rehabilitasyon abalarını optimize edebileceęini ve kaynakları etkili bir řekilde tahsis edebileceęini ne surmřtr (Wesołowski vd., 2017). Bu tr analizler, havalimanı yneticilerinin gvenlik etkileri ve operasyonel ihtiyalara dayalı olarak onarımlara ncelik vermesine ve bylece styapı yapılarının mrn uzatmasına olanak tanır (Babashamsi vd., 2022).

### **Kaplamalı sahalarda gzlenen yzey kusurları**

Havaalanı kaplamalı sahaları esnek styapı, rijit styapı ve kompozit yapı olarak  eřit olarak inřa edilmektedir. Kullanıcı tercihleri, bakım onarım yetenekleri, uuř trafięi ve eřidi ile iklim ve evresel faktrler gzetilerek styapı tercihi yapılmaktadır.

Kaplamalı sahalarda meydana gelen yzey kusurları uuř emniyetini zafiyete uęratabilmekte, uuř trafięinde kesintiye sebep olabilmekte ve restorasyon iin byk btcelere neden olabilmektedir.

Peki bu kadar kritik neme haiz kaplamalı sahalarda meydana gelen kusurların sebepleri nelerdir?

1. Kaplamalı saha tasarımından kaynaklanan projelendirme ve ett hataları
2. Yapım esnasında meydana gelen uygulama, malzeme ve iřilik hataları
3. Kullanıcı birimden kaynaklanan deneyim ve bakım onarım hataları
4. ngrlmeyen trafik kaynaklı bozulmalar
5. evresel ve iklim kaynaklı meydana gelen kusurlar
6. Yerkre hareketleri,

Havaalanı kaplamalı sahalarında tasarım parametrelerini ařan yk seviyelerinin, taban zemininden kaynaklanan sorunların, iřilik veya malzeme kusurlarının ya da evresel/iklimsel sorunların bulunduęunu gsteren grsel deliller atlaklar, delikler, kmeler, oturmalar ve dięer kaplama sorunu trlerini barındıran deformasyonlardır. Havaalanı kaplamalarındaki sorunların meydana gelmesi kullanım kalitesini, havaalanı kaplamaların gvenlięini ve uuř emniyetini ciddi bir řekilde tehdit eder. Sorunların etkilerini hafifletmek hatta mmknse ortadan kaldırmak, havaalanı kaplamasının iřlevsellięini korumak ve uuř trafięinin emniyetli bir řekilde devamını saęlamak iin havaalanlarında etkili ve zamanlı bir bakım programının ve uygun onarım prosedrlerinin uygulanması byk nem arz eder.

Kapamalı saha sorunlarının giderilmesinde en nemli ayak sorunun nedeninin tespit edilmesidir. Onarım sreleri sadece bozulmayı gidermeyi iermez, aynı zamanda sorunun sebeplerinin de ortadan kaldırılarak gelecekte aynı sorunların yařanmasının da nne geer.

Tespit edilen sorun çok küçük dahi olsa, giderilmeyen sorun ileride çok daha büyük ve masraflı problemlere neden olabilir.

Kaplamalı sahaların yüzeylerinin maruz kaldıkları iklim şartları, doğa olayları ve trafik yükleri neticesinde ortaya çıkan deformasyonların uzman ekipler tarafından hızlı ve doğru tespit edilmesi, onarılması ve tesisin tekrar trafiğe açılması gerekmektedir.

Yüzey kusurlarının tespiti genel olarak uzman ekipler tarafından yapılmakla beraber bu işlem ehil personele ulaşım imkanı, personelin tecrübe seviyesi, olası insani hatalar göz önüne alındığında hasar tespitlerine yönelik alternatif çözüm arayışlarını hızlandırmıştır.


### **Esnek kaplamalarda meydana gelen kusurlar**

Kaplama tabakasının bitümlü karışımlar ile oluşturulduğu üst yapıların yüzeyinde oluşan deformasyonlardır. Bu tür kusurlar, iniş-kalkış konforunu ve emniyetini olumsuz etkileyebilir. Esnek üstyapılarda yaygın yüzey kusurları:

#### ***Yüzey deformasyonları***

**Tekerlek İzleri:** Araç tekerleklerinin sürekli geçişi sonucu meydana izler ve çukurlardan oluşan kalıcı bir deformasyon türüdür. Bitümlü sıcak karışım esnek üst yapı her yüklendiğinde meydana gelen az miktarda geri dönüşümsüz deformasyonun toplamı kalıcı deformasyon olarak gözlemlenir (Hanlı,2009).

Rutting prensipte bir stabilite problemi olmakla beraber aşırı trafik yükü, yetersiz kaplama dayanımı ya da kalınlığı ve zayıf taban zemini kaynaklı olabilmektedir. Sorunu iki ana temelde değerlendirebiliriz. İlk olarak esnek tabaka altındaki bulunan temel/alt temel/tabii zemine uygulanan aşırı trafik yükü deformasyona neden olmaktadır. Buradaki deformasyon genelde aşınma/binder tabakalarından ziyade alt tabakalarda meydana gelmektedir. İkinci durumda ise deformasyon bitümlü tabakalarda meydana gelir ki bu durumda kaplama trafik yüklerine karşı koyacak yeterli kayma mukavemetine sahip değildir. Her geçişte kaplamaya yapılan yüklemede meydana gelen küçük ama kalıcı deformasyonlar karışımın aşağı ve yana yer değiştirmesine sebep olmakta ve tekerlek izi deformasyonu meydana gelmektedir. Şekil 15-a'da yapısal tekerlek izi, Şekil 15-b'de akma tekerlek izi, Şekil 14-c'de ise aşınma ve oturma tekerlek izine örnekler verilmiştir.



**Şekil 15.** Tekerlek izinde oturma tipleri (Kutluhan ve Ağar,2009)

Bu tür kalıcı deformasyonlar karayollarında sıklıkla gözlemlenmekle beraber havaalanı kaplamalı sahalarında karayollarına nazaran daha az tekrar sayısı olduğu için çok daha az meydana gelmektedir.

Geçmişte uçaklar daha küçük ve hafifti, ancak Airbus 380 gibi hızlı ve ağır uçakların kullanılmaya başlanmasıyla birlikte pist değerlendirmesinde yeni bir yaklaşıma ihtiyaç duyulmaktadır. Uçak gövdelerinin büyümesi ve ağırlığının artmasıyla kaplamalar daha büyük gerilmelere maruz kalmaya başlamışlardır. Ayrıca, iniş takımlarının tipi ve konfigürasyonu, bir uçağın ağırlığının kaplamaya nasıl dağıtılacağını ve uçak yüküne bağlı meydana gelen defleksiyona karşı kaplamanın tepkisini belirler. Bir uçağın inişinden kaynaklanan darbe yükü, pist kaplamasında defleksiyona neden olan birincil faktördür. Bu nedenle, kaplamanın teknik değerlendirmesi yapılırken kaplamanın ve ilgili yapıların fiziksel ve operasyonel özelliklerinin dikkate alınması önemlidir.

Kaplamada, uçak inişlerinin uyguladığı statik ve dinamik yükler nedeniyle touch-down bölgesinde deformasyon meydana gelir. İniş noktasındaki tekerlek yolundaki bu deformasyon, bir hava alanı kaplamasının işlevsel yeteneklerini belirlerken birincil arıza kriteridir. Günümüzde gözlemlenen bu tip hasarlar trafik hızının düşük olduğu dönüş için yavaşlanan, inişten sonra fren yapılan bölümler ile park için yavaşlanan alanlardadır. Bir karayolunda meydana gelen yoğun tekerlek izinde oturma Şekil 16’da örneklenmiştir.



**Şekil 16.** Tekerlek izinde oturma hasarı (Hanlı,2009)

Rutting probleminin oluşum nedenlerini üç ana başlık altında değerlendirmek mümkündür. Bunlar bitümlü sıcak karışım tabakası ile ilgili problemler, alt tabakalar ile ilgili problemler ve çevresel nedenler. Bitüm oranının fazla olması, filler malzemenin fazlalığı, agrega yapısının uygunsuzluğu, uygun olmayan sıkıştırma işlemi ilk gruba dahil edilebilir. Alt tabakaların kalınlıklarının yetersiz olması, tabi zeminin konsolide olması ve bu tabakaların yana hareketleri ikinci gruba dahil edilebilir. Çevresel etkilere de beklenmeyen ve tekrarlı ağır yüklemeler ile aşırı sıcaklık artışları örnek verilebilir.

## **Dalgalanmalar ondölasyonlar, ötelenmeler ve yorulma hasarları**

Araçların frenlemesi ve hızlanması sırasında tekerlerin mekanik etkisi ile ötelenerek meydana gelen dalgalı yüzey deformasyonlarıdır. Kaplama yüzeyinde ondölasyon, minik yükselteler, çukurlaşma ve düzensizlikler meydana gelir. Bu tür hasarların ana sebepleri bitümlü sıcak karışımının yetersiz stabilitesi, tabakaların serimi esnasında yapılan uygulama hataları ve yetersiz sıkıştırma, ağır trafik etkisi, üstyapı tabakaları arasında oluşan bağlantı zafiyeti gibi nedenler sayılabilir.

### **Lokal oturmalar**

Kaplamada gözlenen düşey yönlü lokal deplasmanlardır. Genellikle temel/alt temel tabakalarının yetersiz sıkışması, üst yapı tabanının yetersiz taşıma gücüne sahip olması, drenaj yetersizlikleri gibi genellikle uygulama hatası kaynaklı sebeplerden meydana gelirler.

### **Çatlaklar**

Çatlaklar genellikle trafik yükünün aşırı tekrarından meydana gelmektedir. Prensip olarak trafik yükü kaplamaya etki ettiğinde ortaya çıkan gerilmeler kaplama mukavemetini aştığında çatlaklar oluşmaktadır. Bunun yanı sıra sıcaklık değişimleri, yanlış agrega ve bitüm tercihleri, yetersiz drenaj koşulları da çatlaklara sebep olabilmektedir.

Çatlaklarda asfaltın çekme mukavemeti çok önemli bir etkidir. Bitümlü karışımlar termoplastik malzemeler olduğundan hava şartlarına göre davranışı değişebilmektedir.

Çatlakların diğer sebepleri yorulma, yetersiz tabaka kalınlıkları, yüksek deformasyonlar sonucunda malzemelerde meydana gelen ayrılmalar, drenaj kusurları, malzemelerin don hassasiyeti, frenaj ve hızlanma esnasında oluşan gerilmeler, uygulamada meydana gelen soğuk derzler ve uygulama kusurları sıralanabilir.

### ***Yorulma (Timsah sırtı) çatlakları***

Yüzeyde küçük, çoklu çatlaklar şeklinde görünür ve genellikle kaplamanın yük taşıma kapasitesinin azalmasıyla ya da aşırı yükleme ile ilişkilidir. Kaplamaya uygulanan yükleme neticesinde çatlamaya neden olacak seviyede gerilme dayanımının aşılması neticesinde meydana gelir. Yorulma çatlağı zaman içerisinde yayılır başlangıçta lastik izi boyunca meydana gelen çatlaklar ilerleyen süreçte timsah sırtına benzer şekilde kaplamaya yayılır. Yorulma çatlakları son evrede trafik etkisiyle kopmalara ve çukurlara neden olmaktadır. Kaplamalı sahalarda en yoğun görülen hasarlardan bir olan timsah sırtı çatlağına dair örnek Şekil 17’de sunulmuştur.



**Şekil 17.** Timsah sırtı çatlağı hasarı

İnce kaplamalar ve zayıf tabakalar tekrarlı ağır yüklemelerde yüksek defleksiyona uğrama potansiyeline sahiptir. Bu durum asfalt tabakanın altında yatay çekme gerilmelerinin artmasına ve nihayetinde yorulma çatlaklarının oluşmasına sebebiyet verir. Uygun drenaj koşullarının sağlanamaması, kaplama kalitesinin yetersizliği de bu duruma neden olabilir. Kaplamada yorulma çatlağı meydana gelmesi hesaplanan trafik sayısına erişildiği anlamına da gelebilir. Burada göz önüne alınması gereken husus hesaplanan trafiğin ön görülen sürede meydana gelip gelmediğidir.

#### ***Enine (Termal) çatlaklar***

Yolun kısa eksen boyunca oluşan çatlaklardır. Genellikle elverişsiz çevresel etkenlerin sebep olduğu çatlaklar olarak değerlendirilirler. Bu çatlaklar termoplastik bir malzeme olan bitümlü kaplanın soğuk havalarda büzülmesi nedeniyle kaplama bünyesinde çekme gerilmeleri meydana gelir, muhtelif bölgelerde çekme dayanımının aşması neticesinde Şekil 18’de görülen bu kusurlar oluşur. Burada ana unsur karışımın bağlayıcısı görevini üstlenen bitümün elastiklik kabiliyetidir. Sert asfaltlar yumuşak asfaltlara nazaran bu deformasyona daha çok meyillidirler.



**Şekil 18.** Termal çatlak hasarı (Hanlı,2009)

#### ***Boyuna çatlaklar***

Yolun uzun eksen boyunca oluşan çatlaklardır. Boyuna çatlaklar, genellikle iki şerit arasındaki derzlerde veya kaplama gövdesi ile banketin birleşim bölgelerinde, yolun eksen doğrultusunda oluşur. Söz konusu çatlaklar dolguda uygulanan sıkıştırmanın şartname değerlerini karşılamaması nedeniyle meydana gelen oturmalarından, dolgu tabakasının yanal


yönde hareket etmesi, drenaj elemanlarının suyun tahliyesinde yetersiz kalması, çevresel ve iklimsel faktörler, kaplamalı saha taşıma gücünün üstyapıya gelen yükleri karşılamada yetersiz kalması gibi nedenlerden dolayı oluşan oturmalar ve Şekil 19’da görüldüğü gibi boyuna derzlerin uygun şekilde imal edilemeyişinden meydana gelebilmektedir.



**Şekil 19.** Boyuna çatlak hasarı

#### ***Çok yönlü bozulmalar (blok çatlaklar)***

Kaplamada meydana gelen Şekil 20’de görülen boyuna ve enine çatlakların kesişerek birleşmesi sonucu harita şeklinde meydana gelen deformasyon çeşididir. Deformasyon önlem alınmadığı ya da çatlak oluşumuna sebep olan hususlar giderilmediğinde ileri safhalarda timsah sırtı çatlaklara evrilir. Kaplamada şişme ve büzülme tesirleri, düşük sıcaklık kaynaklı deformasyonlar, asfaltın yaşlanması sebebiyle elastikiyetini kaybetmesi ve akabinde kırılması sebebiyle meydana gelebilmedir.



**Şekil 20.** Blok çatlak hasarı (Hanlı,2009)

#### ***Kenar çatakları***

Taşıyıcı kaplamalı yol gövdesinin kenarında taşıma gücü zafiyeti ya da üstyapının kenarının aşırı trafik yüküne maruz kalması veya banket bölgesinde yetersiz drenaj gibi nedenlerden meydana gelen çatlaklardır. Örneği Şekil 21’de sunulan hasar tipi daha çok karayolu üstyapılarında görülen deformasyon türlerindendir.




**Şekil 21.** Kenar çatlağı hasarı (Kanburoğlu, 2022)

#### ***Kılcal çatlaklar***

Yüzeyde ince çizgi şeklinde görülen hafif düzeyde bozumalardır. Asfalt karışımının yetersizliği veya yanlış uygulama nedeniyle meydana gelir. Isı farklılıkları, donma çözünme döngüleri de etkili olabilmektedir.

#### ***Yansıma çatlakları***

Asfalt takviye tabakasında meydana gelen deformasyon çeşididir. Ana taşıyıcı gövdede mevcut olan çatlakların Şekil 22’de görüldüğü gibi yüzeye yansıması neticesinde oluşur.



**Şekil 22.** Yansıma çatlağı hasarı (Türk Çimento,2024)

#### ***Asfalt kayması***

Asfalt kayması, yol yüzeyindeki asfalt tabakasının yatay yönde hareket etmesi sonucu meydana gelir. Bu durum, genellikle yolda dalgalı deformasyonlar veya büyük kabarık alanlar olarak kendini göstermektedir. Yüzeyin yatay yönde kayması, genellikle yoğun trafik ve yüksek sıcaklıkların etkisiyle oluşur. Daha çok karayolu kaplamalarında görülen Şekil 23’te görüldüğü gibi bir deformasyon türüdür.



**Şekil 23.** Asfalt kayması hasarı (Erdoğan, 2019)

### ***Yamalar, çukurlar ve obruklar***

Kaplama yüzeyinde 0,1 Mm<sup>2</sup>'den daha büyük bir alanın yeniden yapılması ya da herhangi bir malzeme ilavesi ile doldurulması yama olarak adlandırılmaktadır. Bu bölümlerde meydana gelen deformasyonlar yama kusurları olarak adlandırılır.



**Şekil 24.** Çukur-obruk hasarı

Çevresel ve iklimsel faktörler, yetersiz yüzey drenajı, imalat kusurları, ağır trafik yükleri nedeniyle çapı 10-30 cm, derinliği 5-10 cm arasında ya da daha fazla olan oyuklar “çukur” olarak adlandırılmaktadır. Genellikle yapım sürecindeki hatalardan oluşur. Yüzeyde meydana gelen diğer kusurlar nedeniyle oluşabildikleri gibi, yetersiz üst yapı dayanımı, kalitesiz agrega ve bitüm tercihleri, tabaka kalınlıklarının yetersiz olması sonucu meydana gelebilirler.

Genellikle altyapı sorunları veya su sızıntıları nedeniyle oluşan daha büyük delikler obruk olarak nitelendirilir. Çukur hasarına örnek Şekil 24’te sunulmuştur.

### ***Çok yönlü bozulmalar***

#### ***Yüzey aşınması ve parlama kayma direnci kaybı***

Kaplama yüzeyindeki agregaların trafik etkileri ile aşınmaya maruz kalması nedeniyle aşırı düzleşmesi/pürüzsüzleşmesi sonucu yüzeyin Şekil 25’te görüldüğü gibi kaygan hale gelmesi cilalanma olarak isimlendirilir. Doğal hali yuvarlak yüzeyli kırılmamış agrega kullanımı da neden olabilir ancak içsel sürtünme açısı ve dolayısıyla karışımın stabilitesi düşük olacağından zaten tasarım aşamasında pek tercih edilen bir durum değildir.



**Şekil 25.** Cilalanma hasarı (Erdoğan, 2019)

### *Kusma*

Bitümün özellikle çok sıcak havalarda terleme yapmak suretiyle kaplama yüzeyine çıkmasıyla meydana gelir. Bitümün gereğinden fazla kullanımı, bitümlü sıcak karışımda yeteri kadar boşluk oranı sağlanamayışı, yanlış penetrasyon derecesine sahip bitüm seçimi gibi hususlar neden olmaktadır. Şekil 26’da yoğun bir kusma örneği görülmektedir.



**Şekil 26.** Asfalt kusması hasarı (Insapedia, 2018)

### *Bombelikler*

Trafiğin durduğu ya da yavaşladığı bölgelerdeki trafik etkisi, silindiraj hataları, kaplamanın stabilitesinin yetersiz olması, astar ve yapıştırma tabakalarının hatalı uygulanması, alt tabakalardaki stabilite zafiyetinin yüzeye yansması gibi genellikle imalat hatalarından kaynaklanır.

### *Sökülme, soyulma ve ayrışma*

Kaplama yüzeyinde agrega eksikliği, yer yer meydana gelen çukurluk ve yüzeyde sökülme şeklinde meydana gelir. Yetersiz drenaj, trafik etkisi, kirli agrega kullanımı, uygulama hataları, yetersiz bitüm yüzdesi, yetersiz silindiraj, fazla boşluk oranı ve asfaltın yaşlanması ve sertleşmesi, kırılğan agrega kullanımı bu Şekil 27’de görülen bu deformasyona sebep olan ana unsurlardır.



**Şekil 27.** Soyulma hasarı (Hanlı,2009)

### Çizgisel Agrega kaybı

Doğrusal bir formada meydana gelen agrega kaybıdır. Genellikle sathi kaplamalarda meydana gelir ve bitümün hatalı püskürtülmesi sonucu oluşur.

### Kaplama agregası kaybı

Asfalt kaplama son kat yüzeyinde ayrışma meydana gelir ve yüzeyde asfalt lekeler gözlemlenir. İlerlemesi halinde küçük çukurlar ya da agregasız alanların oluşumuna neden olabilir. Genellikle uygulama hataları sebebiyle oluşur. Yetersiz karışım sıcaklığı, karışımın geç serilmesi, ıslak/kirli agrega kullanımı, silindiraj hataları, uygun olmayan havada serim yapılması gibi hususlar neden olabilir.

Esnek üst yapıli kaplamalı sahalarda gözlemlenen hasar türleri ve oluşma nedenleri Tablo 4'te detaylı bir şekilde listelenmiştir.

**Tablo 3.** Deformasyon-Oluşma Nedeni Tablosu (Hanlı,2009)

| Oluşma Nedeni                    | Trafik | İklim-Çevresel Faktörler | Uygun Olmayan Malzeme | Uygulama Hataları | Bakım Kusurları | Silindiraj Hataları | Asfaltın Yaşlanması | Taşıma Gücü Zafiyeti | Üstyapı Boyutları Hataları | Şişme ve Büzülme Etkisi | Eski kaplama Hataları | Drenaj Yetersizliği |
|----------------------------------|--------|--------------------------|-----------------------|-------------------|-----------------|---------------------|---------------------|----------------------|----------------------------|-------------------------|-----------------------|---------------------|
| Tekerlik İzleri (Rutting)        | X      | X                        | X                     |                   |                 | X                   |                     | X                    |                            |                         |                       | X                   |
| Dalgalanmalar                    |        |                          |                       |                   |                 |                     |                     |                      |                            |                         |                       |                     |
| Ötelenmeler ve Yorulma Hasarları | X      |                          | X                     | X                 | X               | X                   |                     | X                    |                            |                         |                       |                     |
| Lokal Oturmalar                  |        | X                        |                       | X                 | X               | X                   |                     | X                    |                            |                         |                       | X                   |
| Timsah Sırtı Çatlaklar           | X      | X                        | X                     | X                 | X               |                     |                     | X                    |                            |                         |                       | X                   |
| Enine Termal Çatlaklar           |        | X                        | X                     | X                 | X               |                     |                     |                      |                            | X                       | X                     |                     |
| Boyuna Çatlaklar                 | X      | X                        | X                     | X                 | X               | X                   |                     | X                    |                            |                         |                       | X                   |
| Çok Yönlü Çatlaklar              |        | X                        |                       |                   |                 |                     | X                   |                      |                            | X                       | X                     |                     |
| Kenar Çatlakları                 | X      | X                        |                       |                   |                 |                     |                     | X                    | X                          |                         |                       | X                   |
| Kılcal Çatlaklar                 |        | X                        | X                     | X                 |                 |                     |                     | X                    |                            |                         |                       |                     |
| Yansıma Çatlakları               |        |                          |                       |                   |                 |                     |                     |                      |                            |                         | X                     |                     |
| Asfalt Kayması                   | X      | X                        | X                     |                   |                 |                     |                     | X                    |                            |                         |                       |                     |
| Yamalar, Çukurlar, Obruklar      |        | X                        | X                     | X                 | X               | X                   |                     | X                    |                            | X                       | X                     | X                   |
| Yüzey Aşınması ve Parlama        | X      |                          | X                     |                   |                 |                     |                     |                      |                            |                         |                       |                     |
| Kusma                            |        | X                        | X                     | X                 |                 |                     |                     |                      |                            |                         |                       |                     |
| Bombelikler                      | X      |                          | X                     |                   |                 |                     | X                   | X                    |                            |                         |                       |                     |
| Ayrışma Sökülme Soyulma          | X      |                          | X                     | X                 |                 |                     | X                   |                      |                            |                         |                       |                     |
| Çizgisel Agrega kaybı            |        |                          |                       | X                 |                 |                     |                     |                      |                            |                         |                       |                     |
| Kaplama Agregası Kaybı           |        |                          | X                     | X                 |                 | X                   |                     |                      |                            |                         |                       |                     |

## **Rijit kaplamalarda meydana gelen kusurlar**

Rijit kaplamalarda (genellikle beton kaplamalar), havaalanlarındaki pistler, taksi yolları ve apron gibi alanlarda çeşitli kusurlar meydana gelebilir. Bu kusurlar, genellikle çevresel etmenler, tasarım veya inşaat hataları, düzenli bakım eksikliği gibi faktörlere bağlı olarak ortaya çıkabilir. Rijit kaplamalarda sıkça karşılaşılan kusurların bazı örnekleri şunlardır:

### ***Çatlaklar***

Kaplama yüzeyinde rijit kaplamalarda oluşan çatlaklar genellikle genleşme ve büzülme, iklim koşulları, aşırı sıcaklık değişimleri, donma-çözülme döngüleri veya düşük kalitede yapı malzemeleri, uygulama hataları, tasarım yüklemesi üzerinde gerçekleşen ağır uçuş trafik yükü ve yer altı hareketleri gibi faktörlere nedeniyle ortaya çıkar. Bu çatlaklar, zamanla iklim etkisi, donma-çözülme problemleri ve uçak trafiği ile daha da genişleyebilir, yüzeyde meydana gelecek kopmalarla YAMAHA oluşumuna neden olabilecektir. Çatlaklar, iniş ve kalkış sırasında uçak lastiklerine, iniş takımlarına zarar verebilir ve yolcu konforunu etkileyebilir. Özellikle küçük gövdeli jet uçaklarında iniş kalkışlarda maruz kalınan vibrasyon avionic, radar gibi sistemlerde arızalara neden olabilmektedir.

### ***Uzunlamasına, enlemesine ve çapraz çatlaklar***

Uzunlamasına oluşan çatlaklar, yolun uzun eksen boyunca (yani pistin veya yolun yönüne paralel olarak) oluşur. Uzunlamasına çatlaklar özellikle ağır taşıtların sürekli aynı tekerlek izi üzerinde hareket etmesi ve bu durumun bu alanlarda stres birikmesine neden olması nedeniyle meydana gelebilmektedir. Zayıf derz performansı yine uzunlamasına çatlakların oluşum nedenlerinden birisidir. Derzlerin uygun şekilde yerleştirilmemesi veya zamanla dolgunun bozulması bu bölgelerde deformasyona neden olabilir. Bunun yanı sıra rijit kaplamalar sıcaklık değişimlerine karşı duyarlıdır. Uzun eksen boyunca sıcaklık farklılıkları nedeniyle genleşme veya büzülme, uzunlamasına çatlaklara yol açabilir. Uzunlamasına çatlak Şekil 28’de örnek verilmiştir.



**Şekil 28.** Rijit üstyapı kaplamasında görülen uzunlamasına çatlak örneği

### *Köşe çatlakları*

Saha betonlarında köşe çatlakları, genellikle çeşitli nedenlere bağlı olarak anoların köşe bölgelerinde derzlerin birleşim bölgelerinde ortaya çıkan çatlaklardır. Bu çatlaklar, saha betonlarının yük taşıma kapasitesini ve dayanıklılığını etkiler ve onarılmadıkları takdirde daha büyük deformasyonlara ve YAMAHA oluşumuna neden olabilirler. Termal Genleşme ve Daralma, yer değiştirmeler, zemin hareketleri, donma-çözülme döngüleri, kaplama üzerine binen yükler ve sık trafik, köşe detayları, malzeme ve uygulama hataları nedeniyle Şekil 29'da görüleceği üzere köşe kırıkları ve çatlakları oluşabilmektedir.



**Şekil 29.** Rijit üstyapı kaplamasında görülen köşe çatlağı örneği

### *Durabilite "D" çatlakları*

Erken yaşlarda hızlı kuruma, az miktarda terleme nedeniyle oluşan çatlaklardır. Özellikle beton kaplamalarda dış etkenlere karşı dayanıklılığın yetersiz olduğu durumlarda ortaya çıkan çatlaklardır. "D" çatlakları, betonda uzun süreli maruz kalınan çevresel koşullar (sıcaklık değişiklikleri, donma-çözülme döngüleri, kimyasal etkiler) ve malzeme hataları nedeniyle oluşur ve betonun servis ömrünü olumsuz etkiler. Genellikle başlangıç aşamalarında yüzeyde ince ve ağ şeklinde mikro çatlaklar olarak başlar ve hatta gözle görülmeyebilir, ancak zamanla derinleşerek genişler ve daha belirgin hale gelir. Zamanla betonun yapısal bütünlüğüne zarar verir. Oluşum nedenlerine göre "D" Çatlaklarını incelediğimizde:

- **Donma-Çözülme Döngüleri:** Beton, donma-çözülme etkilerine maruz kaldığında, bünyesinde bulunan su donar ve hacmi genişler. Bu durum betona içsel bir basınç uygular ve uzun vadede çatlakların oluşmasına neden olur. Donma çözülme döngüleri neticesinde oluşan bu tip deformasyona Şekil 30'da örnek verilmiştir.



**Şekil 30.** Rijit üstyapı kaplamasında görülen donma çözünme çatlağı örneği

- **Kimyasal Etkiler:** Yüksek oranda tuz, sülfat veya diğer zararlı kimyasallara maruz kalan beton, bu maddelerle reaksiyona girerek zamanla zayıflar ve çatlak oluşumuna yol açar. Özellikle kış mevsiminde kar ve buzla mücadelede kullanılan solüsyonlar kaplamalı rijit kaplamalı sahalarda ciddi hasarlara neden olabilmektedir.
- **Karbonatlaşma:** Betonun yüzeyi atmosfere maruz kaldığında, karbon dioksit betona nüfuz eder ve kalsiyum hidroksitle tepkimeye girerek kalsiyum karbonat meydana getirir. Bu süreç, betonun alkalinitesini düşürerek çatlak oluşumuna zemin hazırlar.
- **Alkali- Silika Reaksiyonu:** Betonun dayanıklılığını olumsuz etkileyebilen kimyasal bir reaksiyondur. Bu reaksiyon, beton içindeki alkali bileşenlerle (özellikle sodyum ve potasyum) silika içeren agregaların (genellikle kum ve taşlar) etkileşime girmesi sonucu gerçekleşir ve bu süreç betonda genleşmeye ve dolayısıyla Şekil 31’de görülen çatlaklara yol açabilir.


Süreç beton içinde bulunan alkali iyonların, su ile çözünerek betonun içinde serbest halde bulunmasıyla başlar. Silika içeren agregalar, alkali iyonları ile reaksiyona girer ve bu reaksiyon sonucunda jel şeklinde bir madde meydana gelir. Alkali-silika reaksiyonunun sonucu olarak oluşan jel, su emerek şişer ve betonun içinde genişlemeye yol açar. Şişen jel, betonun içinde gerilmeye neden olur ve bu da çatlaklara yol açar. Bu çatlaklar zamanla betonun dayanıklılığını azaltır.

Bu durumla karşılaşmamak için karışım dizaynı yapılırken tercih edilen malzeme ocağından gelecek agrega malzemesinin Alkali-Silika Reaksiyonuna yol açmayacak kimyasal niteliklere sahip olması gerekmektedir.

Agrega numuneleri, imalata geçilmeden önce yeterli donanıma sahip ve akredite bir laboratuvarda teste tabi tutulur. ASTM 294 ve ASTM C295, TS 10088'e göre "Beton Agregalarının Petrografik Analizi" yapılırken, eğer gerekliyse petrografik deney sonuçlarına dayanarak bileşimindeki alkali-karbonat potansiyel reaksiyon gösterebilecek agregalar belirlenir. Bu durumda, ASTM C586'ya göre kaya silindirleri yöntemi olarak bilinen "Kireçtaşı Bazlı Beton Agregaların Potansiyel Alkali Reaktivitesi" deneyleri yaptırılarak, elde edilen raporlar incelenir. Uygun görülmeyen agregalar karışımda kullanılmaz.

Betonda kullanılacak standartlara uygun çimentonun ihtiva ettiği çözünebilir toplam Alkali miktarı, (Sodyum oksit eşdeğeri olarak) çimentonun Alkalinite değeri, en çok %0,6 olmalıdır (NGYD,2025).

Betonda Alkali Agrega Reaktivitesine neden olan faktörlerden biri de kullanılacak hidrolik bağlayıcı etkinliğindeki Çimentonun Kimyasal özelliği ile ilgili çözünabilir Alkali Oksit miktarıdır. Bu nedenle, çimentonun ihtiva ettiği Alkali Oksit, kimyasal ve/veya fotometrik analize dayanan ve ( $\text{Na}_2\text{O} + 0.658 \text{ K}_2\text{O}$ ) bağıntısıyla hesaplanarak sodyum oksit eşdeğeri olarak ifade edilen alkali oksit miktarı olup, "Çimentonun Alkalinite değeri" olarak anılır. Kaliteli Beton Kaplamada kullanılacak çimentolar için çözünabilir Alkali Oksit miktarı (Alkalinite Değeri) en çok %0,6 olarak sınırlandırılmıştır (NGYD,2025).



**Şekil 31.** Rijit üstyapı kaplamasında görülen asr sebepli harita çatlağı (Çullu vd,2010)

#### *Derz izolasyonu bozunumu*

Beton kaplamalarda genellikle dilatasyon derzleri kullanılır. Ancak, bu derzlerin yerinde olmaması veya yeterince bakım yapılmaması durumunda ek kusurları meydana gelebilir. Bu kusurlar, betonun genişlemesine ve büzülmesine izin vermez, ya da derzlerde oluşan boşluklar birçok kusura neden olabilmektedir.

#### *Parçalanmalar*

Rijit kaplamalarda meydana gelen parçalanmalar, genellikle çeşitli nedenlere dayalı olarak ortaya çıkan beton yüzeyindeki bozulmalardır. Kimyasal etkenler, özellikle tuzların kullanımı veya endüstriyel atıkların varlığı gibi durumlar, betonun kimyasal dayanıklılığını azaltabilir ve parçalanmaya neden olabilir. Bunun yanı sıra alkali silis reaksiyonu (ASR) sonucu kaplamada çatlaklar ve bozukluklar görülebilmektedir. Bu sebeple kaplamalı saha karışımlarında kullanılan agregaların non reactive olması gerekmektedir. Parçalanma türlerine bazı örnekler aşağıda sıralanmıştır:

- Timsah Sırtı ve yüzey çatlakları
- Katmanlaşma
- Derz ve köşe hasarları,
- Patlamalar
- Katman çatlakları

### *Eğim problemleri*

Rijit kaplamalarda, pistlerde veya taksi yollarında istenmeyen eğim problemleri ortaya çıkabilir. Eğimdeki düzensizlikler, su birikintilerine, drenaj sorunlarına ve uçakların hareket kabiliyetini etkileyebilir.

### *Çarpıklık*


Beton yüzeyin maruz kaldığı çevresel etkiler, aşırı ve tekrarlı yüklemeler ile yapısal düzensizlikler sonucunda meydana gelen deformasyonlardır. Çarpıklık hasarı, beton kaplamaların eğilmesi veya bükülmesi anlamına gelir ve genellikle sıcaklık değişimleri, nem oranındaki farklılıklar veya temel tabakasındaki sorunlar nedeniyle oluşur.

- **Sıcaklık Farklılıkları:** Beton, sıcaklık değişikliklerine karşı oldukça duyarlı bir yapı malzemesidir. Açık alanlarda bulunan rijit kaplamalı sahaların beton yüzeyleri gündüz vakitlerinde çok daha fazla ısınır ve genişir, geceleri ise soğur ve büzülür. Bu sıcaklık farkı, beton plakaların üst ve alt yüzeyleri arasında farklı gerilmeler yaratır ve plakaların köşelerinde yukarıya doğru bir eğilme (çarpıklık) meydana getirebilir.
- **Nem Farklılıkları:** Betonda nem kaybı, özellikle yüzeyde daha hızlı gerçekleşir. Bu durum, beton plakaların üst kısmının alt kısımdan daha hızlı büzülmesine neden olur ve sonuçta beton levhaların köşeleri yukarı doğru kalkabilir. Nem farklılıkları, uzun vadede ciddi deformasyonlara yol açabilir. Bu yüzden beton uygulamasından sonra hidrasyon ısısı düşüp kimyasal reaksiyonlar bitene kadar beton yüzeyleri nemli tutulmalı, beton karışımındaki suyun hızlı kaybının önüne geçilmelidir.
- **Yetersiz Derz Yerleşimi:** Beton plakalar arasında yeterli sayıda ve doğru konumda derzlerin bulunmaması, sıcaklık ve nem farklılıklarından kaynaklanan gerilmelerin düzgün bir şekilde kontrol edilememesine neden olur. Derzler, bu tür gerilmeleri absorbe etmek ve betonun çarpılmasını önlemek için kritik öneme sahiptir.
- **Zayıf Zemin veya Alt Temel Koşulları:** Beton kaplamanın oturduğu alt temel veya temel tabakasının yeterince sağlam olmaması, özellikle su sızıntılarıyla zayıflayan bölgelerde, betonun alt katmanlarına destek sağlamada yetersiz kalabilir. Bu durumda beton levhalar farklı şekillerde eğilip bükülerek çarpıklık hasarına yol açabilir.
- **Donma-Çözülme Döngüleri:** Beton yüzeylerinde donma-çözülme döngüleri, özellikle nemli bölgelerde çarpıklığa yol açabilir. Donma sırasında suyun

genleşmesi beton plakalar üzerinde düzensiz gerilmelere neden olur ve bu da plakaların bükülmesine neden olabilir.

#### *Göçükler ve delikler*

Pist yüzeyindeki göçükler, genellikle yer altında oluşan bozulmalar, erozyon, su birikmesi veya aşırı yüklenme nedeniyle meydana gelebilir. Göçükler, iniş ve kalkış sırasında uçaklara düzensiz bir zemin sunarak tehlike oluşturabilir. Pist yüzeyindeki delikler, genellikle aşırı kullanım, korozyon, malzeme yorgunluğu veya kötü bakım nedeniyle oluşabilir. Ayrıca atmosferik şartlara maruz kalan beton kaplamada, beton bileşeni olarak kullanılan agreganın içerisinde su ile şişen kil mineralleri kalması durumunda Şekil 32-a ve Şekil 32-b’de görülen kil topağı oyukları meydana gelebilmektedir. Bu delikler, onarılmadığında donma çözünme döngüleri neticesinde büyüyüp genişleyebilir, uçak lastiklerinin ve iniş takımlarının zarar görmesine ve iniş-kalkışlarda düzensizliklere neden olabilir.



**Şekil 32.** Kil topağı oyukları (Türk Çimento, 2024)

#### *Beton yüzeyinin aşınması*

Rijit kaplamalarda beton yüzey aşınması, genellikle trafik yükü, hava koşulları ve kimyasal etkiler nedeniyle betonun yüzeyinin zamanla aşınmasını ifade eder. Özellikle soğuk iklimlerde kar ve buzun eritilmesi amacıyla kullanılan tuzlar, beton yapılarına zarar verebilir. Tuzlar, kar ve buzun eritilmesi amacıyla kullanıldığında, tuzlar ile beton arasındaki kimyasal reaksiyonlar ve tuzun aşındırıcı etkisi nedeniyle beton yüzeyi aşınabilir. Bu durum, betonun yüzeyinde pürüzlerin artmasına ve dayanıklılığının azalmasına yol açabilir.

### *Kayma direnci kaybı*

Rijit kaplamalardaki yüzey kusurları, düzenli temizlik ve bakım yapılmadığında daha da belirgin hale gelebilir. Kirlilik, su birikintileri ve yabancı maddelerin birikmesi, genel güvenlik ve performansı etkileyebilir. Özellikle inişlerde ve frenleme esnasında uçak lastiklerinin Şekil 33'te görüldüğü gibi kaplama üzerine bıraktıkları kauçuk parçaları yüzeyde önemli bir sürtünme kaybına neden olmaktadır. Bu nedenle havaalanlarında düzenli olarak kauçuk temizliği yapılmaktadır.

- Parlamlı agregat
- Pislikler



**Şekil 33.** Rijit üstyapıda gözlenen kirlenme örneği

Hava alanlarında yüzey kusurları, düzenli bakım ve denetimlerle havaalanı yetkilileri ve bakım ekipleri, tarafından tespit edilmeli ve düzeltmek için düzenli olarak bakım ve onarımları gerçekleştirmelidirler. Bu uçak trafiğinin güvenliğini, havaalanı altyapısının uzun ömürlülüğünü ve yolcu konforunu sağlamaya yardımcı olur.

### **Havaalanı kaplamalarında meydana gelen yüzey kusurlarının tespit yöntemleri**

Havaalanı PAT sahalarının durumu, meteorolojik koşullar, zemin hareketleri ve trafik nedeniyle sürekli olarak bozulmakta ve kapma, delikler ve çatlaklar gibi kusurların oluşmasına neden olmaktadır. Havaalanı kaplamalarında meydana gelen yüzey kusurlarının tespit edilmesi, uçuş güvenliği, pist ve taksiyollarının ömrünü uzatmak açısından büyük önem taşır. Havaalanı işletmeciliğinin en önemli görevlerinden ve uzmanlık gerektiren görevlerinden birisi kaplamalı sahalardaki deformasyonları takip etmek, gerekli iyileştirmeleri yapmak ve tesisi her daim uçuşa emniyetli bir şekilde hazır tutmaktır. Yüzey kusurları, asfalt ya da beton pistlerde zamanla meydana gelebilecek çatlaklar, aşınmalar, oyuklar, oturmalar, kabarmalar veya deformasyonlar gibi problemleri içerir. Bu tür kusurların tespit edilmesi için çeşitli yöntemler kullanılır.

### **Görsel denetimler**

Klasik bir metot olan görsel denetimler eğitimli teknik personelin pist üzerinde yürüyerek veya araçla yaptığı gözle kontrolü içerir. Pistin yüzeyinde çatlaklar, çukurlar veya aşınmalar gibi gözle görülebilecek kusurlar aranır. Yaygın olarak kullanılan bir yöntem olmakla beraber insan hatasına açıktır. Küçük kusurlar, çok ince çatlaklar gözden kaçabilir, geniş alanların hızlı ve efektif bir biçimde taranması zordur. Pist inceleme devam ederken uzun süre trafiğe kapalı kalabilir. Bu sebeple kaplamadaki kusurları hızlı ve doğru bir şekilde tespit etmek için otomatik çatlak tespiti çok önemli bir çalışma alanıdır.

### **Termal görüntüleme metotları**

Tüm nesneler sıcaklıklarının bir fonksiyonu olarak kızılötesi enerji (ısı) yayarlar. Genel olarak, bir nesne ne kadar sıcaksa o kadar fazla radyasyon yayar. Bir termal kamera (termal kamera olarak da bilinir) esasen sıcaklıktaki küçük farklılıkları tespit edebilen bir ısı sensörüdür. Cihaz, sahnedeki nesnelerden gelen kızılötesi radyasyonları toplar ve sıcaklık farkları hakkındaki bilgilere dayanarak elektronik bir görüntü oluşturur. Bu yöntemde termal kameralar kullanılarak kaplamalı saha yüzeyindeki sıcaklık farkları tespit edilir. Görüntü oluşumu açısından optik görüntülemeden farklıdır. Optik görüntüleme ışık yardımıyla görüntü oluştururken, termal görüntüleme nesneler tarafından yayılan ısı ile görüntü oluşturur. Kusurlu alanlar, özellikle alt tabakalarda bulunan boşluklar ve çatlaklar, termal anormallikler oluşturur. Termal kameralar bu sıcaklık farklılıklarını tespit ederek kaplama yüzeyi ve altındaki durumlar hakkında bilgi verir. İyi aydınlatılmamış veya sis ve yağmur gibi hava koşullarına sahip alanlarda kullanılabilmektedir (Aparna *et al.* 2019).

Yollardaki çukurların tespitinde kullanıcılar manuel raporlamadan titreşim tabanlı sensörlerin kullanımına ve lazer görüntüleme kullanılarak 3D yeniden yapılandırmaya kadar çeşitli teknikler uygulanmıştır. Ancak tüm bu tekniklerin yüksek kurulum maliyeti, tespit sırasında risk veya gece görüşü için hüküm bulunmaması gibi bazı dezavantajları vardır. Bu nedenle Aparna ve arkadaşları çalışmalarında çukur tespiti alanında termal görüntülemenin fizibilitesini ve doğruluğunu analiz etmişlerdir. Çeşitli koşullar ve hava koşulları altında çukurların görüntülerini içeren uygun miktarda veri toplandıktan ve veriler üzerinde artırma teknikleri uygulandıktan sonra, termal görüntüleme kullanılarak bu problem alanında yeni bir yaklaşım olan derin öğrenmenin evrimsel sinir ağları yaklaşımı benimsendiğini belirtmişlerdir. Ayrıca, kendi oluşturduğu konvolüsyonel sinir modeli ile önceden eğitilmiş bazı modeller arasında bir karşılaştırma yapılmıştır. Sonuçlar, görüntülerin önceden eğitilmiş evrimsel sinir ağları tabanlı artık ağ modellerinden biri kullanılarak %97,08'lik en iyi doğrulukla doğru bir şekilde tanımlandığını tespit etmişlerdir. (Aparna *et al.* 2019)

Termal kameralar yüzey altındaki kusurların tespit edilmesinde etkilidir ve geniş alanları hızlı bir şekilde taranmasını sağlar. Yol kusurları gözle görülemez aşamadayken termal kameralarla tespit edilebilir. Bu, erken müdahale ve hasaralar daha da ilerlemeden onarım şansı sunar. Erken tespit edilen sorunlar, büyük onarımlar veya yol kapanmaları gibi daha maliyetli işlemlerin önüne geçer. Termal kameralar, gece, sis, yağmur veya kar gibi hava koşullarında da etkili bir şekilde çalışabilir. İnceleme yapılan ulaştırma altyapısının tamamen kapatılmasına gerek kalmadan hızlı ve etkili bir denetim sağlanabilir.

Bunun yanı sıra ekipman/araç-gereç maliyeti yüksektir ve doğru sonuçlar elde edebilmek için termal kameraların düzenli olarak kalibre edilmesi çok önemlidir. Termal görüntüleme verilerinin doğru bir şekilde yorumlanması, özel eğitim gerektirir. Bazı durumlarda çevresel koşullar (sıcaklık, güneş ışığı, mevsimsel faktörler) inceleme sonuçlarını etkileyebilir. Termal kameralar kullanılarak aşağıda sıralanan tespitler yapılabilmektedir.

### ***Radar tabanlı yöntemler***

Radar tabanlı yöntemler, kaplama üstyapısı kusurlarının tespitinde kullanılan teknolojilerden biridir. Kaplama tabakası yüzeyinin altındaki katmanların durumunu ve olası kusurları belirlemek için elektromanyetik radyo dalgaları gönderilir. Radar tabanlı yöntemler, ulaştırma üstyapısının yapısal bütünlüğünü incelemek, çatlaklar, su birikintileri, boşluklar ve diğer yapısal sorunların erken aşamalarda tespiti için uygun bir metottur. Ancak kullanılan ekipmanların karmaşıklığı ve verilerin doğru yorumlanması için uzmanlık gerektirir.

Son 20 yılda, uydu tabanlı Sentetik Açıklıklı Radar İnterferometrisinin (InSAR) farklı türdeki varlıkların yüzey deformasyonlarını doğru bir şekilde tespit etme kabiliyetini ortaya koyan zengin bir literatür oluşmuştur. Ölçümlerin yüksek doğruluğu ve mekânsal yoğunluğu ile yeniden inceleme süresi sayesinde, uzay kaynaklı uzaktan algılama teknikleri uygun maliyetli ve neredeyse gerçek zamanlı bir izleme aracı sağlama potansiyeline sahiptir. İnşaat mühendisliği prosedürleri için büyük altyapı envanterleri ile birlikte analiz edilmesi gerekir. Bölgesel ölçekte, InSAR'dan türetilen yer değiştirmelerin tek tek manuel olarak çıkarılması son derece zaman alıcıdır ve altyapı sistemlerinin etkili bir şekilde değerlendirilmesi için iki veri setinin otomatik entegrasyonu gereklidir (Macchiarulo *et al.* 2022,)

- **Zemin Radarı (Ground Penetrating Radar- GPR):** GPR, yakın yüzey araştırmalarında kullanılan yüksek frekanslı elektromanyetik dalgaların yayılmasına dayanan tahribatsız bir test yöntemidir (EVREN, t.y.).

GPR yöntemi; yapıların sağlık durumunun değerlendirilmesinde, zemin yapısının ortaya çıkarılmasında, yüzeye yakın zemin birimlerinin tespitinde, deprem fay hatlarının

belirlenmesinde, karstik boşlukların saptanmasında ve yeraltı su seviyesinin belirlenmesinde yaygın olarak kullanılmaktadır (Kılıç,2022).

Kullanımda olan bir kaplamalı yüzeyin performansının analiz edilmesinde ve yapısal analizinde yapısal durumunu değerlendirmede tahribatsız testler (Nondestructive Testing-NDT) en güvenilir yöntemlerden biri olarak kabul edilir. NDT, tahribatlı deneylere kıyasla iki önemli avantaja sahip olmakla beraber bu avantajları tahribatlı yöntemlerin kaplama üstyapısına zarar vermesi ya da test için yapıdan malzeme alınmasının gerekli olmasıdır. Fakat tahribatsız yöntemler yapıya zarar vermeden inceleme yapılmasına olanak tanır. İkinci olarak ise, NDT yöntemleri genellikle daha düşük maliyetlidir ve trafiğin daha az kesintiye uğramasını sağlar. Bu teknik üstyapıdaki yapısal değişimlerin ve anormalliklerin konumlarının tespitinde, üstyapı tabaka kalınlıklarının ölçülmesinde, beton plakların altındaki boşlukların belirlenmesinde, beton üstyapılarda birleşim noktalarındaki öngerme ve tutturma elemanlarının yerlerinin saptanmasında ve asfalt üstyapılarda nem kaynaklı hasarların tespitinde kullanılmaktadır (Serin vd, 2022.).


GPR, yolların yüzeyine elektromanyetik dalgalar göndererek yansımalarını kaydeder. Bu dalgalar bir engelle karşılaştıklarında GPR'ye doğru yansıtılır. GPR farklı dalgaların varış zamanlarını kaydeder ve incelenen nesne boyunca ilerledikçe bunları toplar. Bu ölçümlerin toplamı, yapının ve bileşenlerinin grafiksel bir gösterimi olan bir radargram oluşturur. Dalgalar farklı malzemelerden geçerken yansır ve bu yansımalar, yüzey altındaki farklı yapıların ve kusurların tespit edilmesine olanak sağlar. Yolun altındaki malzeme tabakaları, boşluklar, çatlaklar ve su birikintileri gibi anormallikler farklı radyo dalgaları yansımalarına neden olur.



**Şekil 34.** GPR uygulaması örneği (FPrimeC, t.y.)

Yolların altındaki boşluklar, dolgu malzemesinin yer değiştirdiği veya çöktüğü alanlar GPR kullanılarak tespit edilebilir. Radyo dalgalarının bu boşluklardan yansıma şekli, yüzey altındaki sorunların tespit edilmesine yardımcı olur. GPR uygulamasına tekniği Şekil 34-a'da, tarama sonucu oluşan data Şekil 34-b'de, çalışma prensibine dair görsel Şekil 35'te sunulmuştur.

GPR, suyun bulunduğu alanlarda farklı yansımaya özellikleri gösterir. Bu sayede, yolun altındaki su birikintileri ve nem bölgeleri belirlenerek donma-çözülme döngüsünün yol açacağı hasarların önceden tespiti sağlanır.



Şekil 35. GPR uygulaması örneği

Yukarıda verilen bilgiler ışığında yapılan değerlendirmede Zemin Radarları için aşağıdaki çıkarımlar yapılabilir;

- **Yapısal Değişimlerin Tespiti:** Radar tabanlı sistemler, asfalt ve beton üstyapıların yüzeyinde ve altındaki farklı tabakaları görüntüleyerek bu tabakalardaki bozulmaları ile asfaltın ya da betonun altında oluşan delaminasyon (tabaka ayrılması) bölgeleri tespit edilebilir. Bu ayrışmalar, yolun yüzeyinde farklı refleksiyonlar yaratır. Radar sinyalleri bu bölgelerde farklı bir yansımaya sağlar ve görüntüleme sağlanır.
- **Derinlik Taraması ve Yol Yapısı:** Radar teknolojisi, yolun yüzeyinin altındaki farklı derinliklerde bulunan kaplama tabakalarını inceleyebilir. Zemin radarı, yolun yapımında kullanılan malzeme tabakalarının kalınlığı ve yapısal bütünlüğü hakkında bilgi sağlar. Bu sayede yolun yapısal durumu hakkında fikir sahibi olunur. Radar dalgaları, yol altındaki toprak ya da dolgu malzemesinin sıkışma durumunu inceleyebilir. Eğer zemin düzgün sıkıştırılmamışsa veya zamanla ayrışma ya da sıkışmada zafiyet meydana gelmişse, bu radar verilerinde anormallik olarak görülür.
- **Donma-Çözülme Döngüsü Tespiti:** Yolun altındaki suyun donması ve erimesi sonucunda yol yüzeyinde çatlaklar ve hasarlar oluşabilir. Radar tabanlı sistemler, bu tür hasarları ve donma-çözülme döngüsünün yolun alt yapısına verdiği zararları tespit edebilir. Donmuş bölgeler radar sinyallerini farklı bir şekilde yansıttığı için bu tür yapısal değişiklikler erken aşamada fark edilebilir. Donma ve erime sırasında yolun altındaki suyun hareketini izlemek için GPR kullanılabilir. Bu bilgi, buzlanma öncesinde alınacak önlemler için kritik öneme sahiptir.

Serin ve arkadaşları halihazırda kullanımda olan bir üstyapının yapısal durumunun belirlenmesinde en güvenli yöntemlerden birinin tahribatsız-NDT (Nondestructive Testing-NDT) testler olduğunu belirtmişlerdir. Bunun yanı sıra üstyapı tabaka kalınlıklarının da tahribatsız metodlarla tespit edilebileceğini bildirmişlerdir. Bir başka kazanım olarak radar görüntülerinin analizinde tabakalarda oluşan anormalliklerin de görüntülerde tespit edilebildiği ortaya konulmuştur. Zemin radarı ile yapılan çalışmalar neticesinde GPR kullanımının test ve görüntülemelerin üstyapıya hasar vermeden gerçekleştirilmesi ve zaman kullanımı açısından efektif olması nedeniyle kalite kontrol çalışmaları için oldukça önemli olduğu belirtilmiştir. (Serin vd,2022)

Radar Tabanlı Yöntemlerin Avantajlarını özetleyecek olursak; portatif olması, çevreye olumsuz bir etkisinin olmaması, hızlı veri toplama olanağı sağlaması, yüksek çözünürlüklü yer altı verisi alınması, kaplama yüzeyine zarar vermeden ölçüm yapılması, hızlı ve çok sayıda veri alınması olarak özetlenebilir (Evren, t.y.).

GPR, yol yüzeyinin altındaki farklı derinliklerdeki tabakaları ve kusurları tespit edebilir, böylece sadece yüzey değil, derin yapı da incelenebilir. Yol yüzeyindeki küçük çatlaklar, boşluklar ve tabaka ayrılmaları gibi küçük anormallikler bile radar sayesinde yüksek hassasiyetle tespit edilebilir. Radar tabanlı yöntemler, yolların kapanmasına gerek kalmadan temassız bir şekilde inceleme yapılmasına olanak tanıyan tahribatsız bir yöntemdir. Radar teknolojisi, yağmur, sis, kar gibi hava koşullarından etkilenmeden çalışabilir.

Radar Tabanlı Yöntemlerin Dezavantajlarını radar sistemleri ve ekipmanlarının özellikle büyük altyapı projelerinde yüksek maliyetli olması, radar verilerinin doğru bir şekilde yorumlanmasının özel eğitim ve deneyim gerektirmesi, radar dalgalarının, yüksek iletken bir ortamda performansın düşmesi ya da çalışmaması, inceleme derinliği arttığında çözünürlüğün azalması olarak sıralanabilir. Zeminin yüksek iletkenli olması durumunda GPR yöntemi kısmi olarak pasif duruma geçebilir ve farklı antenler ile ekstra ölçümlere ihtiyaç duyulabilir. Bazı materyallerde belirli bir mesafeye kadar etkin sonuç alınabilmesi, yol altındaki çok derin tabakalar veya yoğun su içeren bölgelerde radar sinyallerinin nüfuz etmesini güçleşmesi diğer handikaplardandır (Evren, t.y.).

### ***Lazer taraması yapılması***


Veri toplama ve işleme ihtiyacını karşılamak için Şekil 36'daki gibi büyük özel araçlar veya robotik arabalar kullanılabilir. Lazer sensörler yardımıyla pistin detaylı üç boyutlu yüzey haritaları oluşturulur. Bu yöntemle yüzeydeki pürüzlülük, deformasyon ve eğim farklılıkları tespit edilebilir. Yine lazer teknolojisi kullanılarak yanal ve uzunlamasına düzgünlük ölçülür.

Çekiş, enine monte edilmiş bir tekerlek kullanılarak ölçülür. Yüzey dokusu kameralarla taranır ve dijital olarak kaydedilir. Yüksek hassasiyete sahiptir ve detaylı yüzey analizi sağlar. Tespit yöntemi, 1,0 mm ve üzeri çatlak genişliklerinin güvenilir bir şekilde tespit edilmesini sağlamaktadır. Şekil 37’de Multi-Laser Profilometre Ölçüm Cihazı Çalışma Prensibi, Şekil 38’de Line-Laser Profilometre Ölçüm Cihazı Çalışma Prensibi verilmiştir. Durum değerlendirmesi yalnızca kanıtlanmış eğitimli personel tarafından yapılabilir. Ancak bu araçlar pahalıdır ve erişimi zordur. Ayrıca veri işleme süreci zaman alabilmektedir.



**Şekil 36.** Lazer uygulaması örneği (IT-ZEB Server, t.y.)

Karayolu Üstyapıları ve Havaalanı Kaplamalarının Fonksiyonel durumlarının belirlenmesi amacıyla yurtiçi ve yurtdışında Şekil 39’da görülen Profilometre Ölçüm Cihazı ile ölçümler yapılmaktadır. Profilometre Ölçüm Cihazı kaplamanın profilini lazer ve akselerometre sistemi ile toplayarak, IRI (International Roughness Index), Tekerlek İzinde Oturma (TİO) ve Yüzey Bozulmaları Görüntüsü ölçümleri yapmaktadır. Profilometre ölçüm cihazı ile aynı zamanda Küresel Konum (GPS), Ölçüm Hızı gibi ilave verileri de toplamaktadır (WARRIP, 2019). Düzgünsüzlük (IRI), tekerlek izinde oturma (TİO), makro doku, atalet hareket Verileri (Geometrik Ölçümler), yol yüzey bozulma görüntüleri ölçümleri bu araçla kullanılmak suretiyle yapılabilmektedir.



**Şekil 37.** Multi-laser profilometre ölçüm cihazı çalışma prensibi (WARRIP, 2019)



**Şekil 38.** Line-laser profilometre ölçüm cihazı çalışma prensibi (WARRIP, 2019)



**Şekil 39.** Profilometre ölçüm cihazı

#### **Yüzey deformasyonlarının tespiti**

- **Yüzey Pürüzlülüğü ve Düzensizlikler:** Lazer tarama metoduyla, yol yüzeyindeki en küçük düzensizlikler dahi çok hassas bir şekilde tespit edilebilmektedir. Yolun düzgünlüğü, pürüzlülüğü ve deformasyonları milimetre hassasiyetiyle ölçülür. Bu deformasyonlar, zamanla yolun yapısal bütünlüğünü bozarak güvenliği tehdit edebilir (Deveci vd, 2021).
- **Çatlakların Tespiti:** Yüzeydeki çatlaklar lazer tarayıcılarla kolayca algılanabilir. Yüksek çözünürlüklü 3D tarama verileri, çatlakların boyutlarını, genişliklerini ve derinliklerini analiz ederek, küçük çatlakların ileride büyük problemlere yol açmadan önce onarılmasına olanak tanır (WARRIP, 2019).

#### **Çökme ve dalgalanmaların belirlenmesi**

- **Yüzey Çöküntüleri:** Yol yüzeyindeki çökmeler, lazer tarama cihazları ile hızlıca tespit edilebilir. Lazer tarama, yolun belirli bölgelerinde yüzeyin altındaki malzemelerde meydana gelen zayıflıkların neden olduğu çökmeleri ve deformasyonları haritalar (Deveci vd, 2021).
- **Dalgalanma ve Şekil Bozuklukları:** Yüksek çözünürlüklü lazer tarayıcılar, yolun eğimlerinde, yüzey seviyesinde meydana gelen dalgalanma veya yükselmeleri de ölçebilir. Bu tür kusurlar, özellikle hız yollarında güvenlik riski oluşturur (WARRIP, 2019).

### **Yolun drenaj ve su birikintisi sorunları**

- **Yüzey Eğimi ve Drenaj Sorunları:** Lazer tarama, yol yüzeyinin eğim profillerini analiz ederek su birikintisi veya drenaj sorunlarına neden olabilecek bölgeleri tespit eder. Lazerle elde edilen detaylı topografik haritalar, yolların düzgün su tahliye etmesi için gerekli düzeltmelerin yapılmasına olanak tanır.
- **Su Birikintisi Alanlarının Tespiti:** Yol yüzeyindeki küçük çöküntüler su birikintilerine yol açabilir. Lazer tarayıcılar, bu tür alanları tespit ederek, yağmur suyu birikintilerinin yolun yapısına zarar vermesini veya kayma tehlikesi oluşturmasını engelleyebilir.

### **Aşınma ve malzeme bozulmalarının tespiti**

- **Aşınma Takibi:** Yolun yoğun kullanılan bölgeleri zamanla aşınır. Lazer tarama teknolojisi, yol yüzeyinde aşınan malzemeleri tespit ederek, yol bakım programlarının optimize edilmesine yardımcı olur. Bu sayede yolların aşırı yıpranmadan önce onarımı yapılabilir.
- **Malzeme Bozulmaları:** Asfalt ya da beton yolların yüzeyindeki malzeme bozulmaları, çatlama veya ufalanma gibi belirtiler lazer tarama sistemleriyle kolayca algılanabilir. Bu veriler, yolun yeniden kaplanması gereken bölümlerini belirlemek için kullanılır.

### **Kapsamlı 3D haritalama ve veri analizi**

- **Üç Boyutlu Haritalama:** Lazer tarayıcılar, yolların tam 3D haritalarını oluşturabilir. Bu haritalar, yol yüzeyinin eğimleri, çıkıntıları ve kusurlarının milimetrik hassasiyetle analiz edilmesini sağlar. Yol mühendisleri, bu 3D verileri kullanarak bakım ve onarım planlarını optimize edebilir (WARRIP, 2019).
- **Büyük Ölçekli Alanların Hızlı Taranması:** Lazer tarama teknolojisi, geniş alanların hızlı ve ayrıntılı bir şekilde taranmasını sağlar. Karayolu altyapısının tamamen kapanmasına gerek kalmadan, lazer tarama cihazları mobil araçlara monte edilerek hareket halinde ölçüm yapılabilir (WARRIP, 2019).

Lazer taramasının avantajları; yol kusurlarını milimetre seviyesinde hassasiyetle tespit edilebilmesi, geniş alanların hızlı bir şekilde taranarak detaylı 3D veriler sağlanması, yol kapama gereksinimlerinin minimuma inmesi, yol yüzeyine fiziksel olarak müdahale etmeye gerek kalmadan, lazer tarayıcıların temassız/tahribatsız bir şekilde verileri toplayabilmesi, yüksek çözünürlüklü taramaların, yüzeydeki küçük kusurları bile net bir şekilde ortaya

ıkarabilmesi, sadece yollar deęil, kprler, tneller ve dięer altyapılar zerinde de kullanılabilmesi olarak sıralanabilir.

Lazer taramasının dezavantajları ekipmanları ve sistemleri, zellikle geniř aplı altyapı projelerinde yksek maliyetli olması. Lazer tarama cihazlarının topladıęı verilerin ok byk hacimlerde olması, bunun da veri ynetimini ve analizini karmařık hale getirmesi, lazer tarama verilerinin yorumlanması, doęru analizler yapabilmek iin eęitimli uzmanlar gerektirmesi olarak sıralanabilir.

### ***Grnt analiz yntemleri***

styapı kusurlarının tespiti iin etkili ve yaygın kullanılan teknolojilerden biridir. Son yıllarda yksek hızlı ve znrlkl kameraların ve depolama teknolojilerinin geliřmesiyle byk lekli alanlarda alıřmak ve verileri depolamak nispeten kolaylařmıřtır. Bu yntemler, yolların yzeyindeki atlaklar, ukurlar, ařınmalar, delikler ve dięer kusurların otomatik olarak tespit edilmesine ve sınıflandırılmasına olanak tanır. Yapay zeka algoritmaları ve bilgisayarla grme (computer vision) teknikleri bu tr analizlerde nemli rol oynamaktadır. Geniř alanlar hızlı bir řekilde taranır ve grnt analizi ile otomatik tespit yapılabilir. Hava kořullarına baęlı olarak ekim kalitesi etkilenebilmektedir (Deveci vd, 2021).

### ***Yksek znrlkl grntleme ve veri toplama***

- **Kamera Sistemleri:** Yol yzeylerinin detaylı grntlerini toplamak iin aralara monte edilmiř yksek znrlkl kameralar kullanılır. Bu kameralar, hızla hareket eden aralarla bile yolun yzeyini net bir řekilde tarar ve veri toplar.
- **Uydu Grntleme:** Bazı durumlarda, byk alanları izlemek iin uydu grntleme teknolojileri kullanılır. Yksek znrlkl uydu grntleri, zellikle geniř blgelerdeki yol aęlarının izlenmesi ve byk kusurların tespiti iin uygundur.

### ***Bilgisayarla grme (computer vision) teknolojisi***

Bilgisayarla grme, grsel veriler kullanmak suretiyle farklı bilgi trlerini elde etmeyi amalayan ok eřitli grevleri kapsayan teknolojik geliřmelerdendir. Grnt sınıflandırma, nesne algılama, grnt segmentasyonu, poz tahmini, nesne takibi ve optik akıř gibi grevleri yerine getirme yeteneęine sahiptir (Ultralytics, 2025).

Koch ve arkadaşları inřaat mhendislięi uygulamaları iin bilgisayarla grme yntemlerinin oluřturulma ve kullanılma oranı katlanarak arttıęından, beton ve asfalt sivil altyapı ile ilgili bilgisayarla grme tabanlı kusur tespiti ve durum deęerlendirmesinde son

teknolojinin kapsamlı bir sentezini sunmuşlardır. Çatlak ve hasar tespiti üzerine yapılan pek çok araştırma üzerine detaylı bir derleme yapmışlardır. Gerçek zamanlı bir ortamda tam otomatik ve kapsamlı kaplama kusuru tespiti ve sınıflandırmasının zorluğunu vurgulamışlar, asfalt kaplamaların kusur ve durum değerlendirmesi için problemin ciddiyet seviyesini belirlemek için kapsamlı ve sağlam bir yöntem mevcut olmadığını, genel olarak, inşai altyapının güvenilir kusur tespiti ve durum değerlendirmesinin sadece görsel denetim yöntemlerine dayandırılmaması gerektiğini öne sürmüşlerdir. Görsel değerlendirme tekniklerinin (manuel veya CV destekli) yanı sıra, genel durumu değerlendirmek için sonik, ultrasonik, manyetik, elektrik, nükleer, termografi, radar teknolojileri gibi diğer gelişmiş derinlemesine denetim yöntemlerinin (Tahribatsız değerlendirme-Nondestructive Testing (NDT)) yöntemleri olarak adlandırılır) gerekli olduğunu savunmuşlardır (Koch *et al.* 2015).

Kanaeva ve Ivanova çalışmalarında Rusya Hükümeti'nin istatistiki verilerine göre 2018 yılında tüm yüklerin %67,1'i karayolu ile taşındığını, son yıllarda taşıma hacmi ve özel araç sayısı da sürekli olarak arttığını, bu faktörlerin yol kaplamasının durumunu önemli ölçüde etkilediğini, yol sisteminin bozulması da yük taşıma hızının düşmesine ve trafik kazalarının artmasına yol açtığını belirtmişlerdir. Bu nedenle yol sistemi kalitesinin izlenmesi görevinin olmazsa olmaz bir yaklaşım olduğunu öne sürmüşlerdir. Rusya Federasyonu'nda meydana gelen her üç trafik kazasından biri yol sisteminin yetersiz bakımı ve döküşmesi nedeniyle meydana geldiğinden hareketle yol kusurlarının tespitini ve hızlıca giderilmesi gerektiğini vurgulamışlardır. Çalışmaya göre yol durumu kontrolünün otomatikleştirilmesi, bilgisayarla görme yöntemlerinin pratik uygulaması için mevcut eğilim olup yol bozukluğu tespit probleminin analitik incelemesi, sürücü görüş görüntüsünde piksel seviyesinde çatlak tespitinin öncelikli ve zorlu bir görev olduğunu göstermiştir. Yol kaplaması içeren görüntülerdeki çatlakların segmentasyonu için sentetik eğitim verisi üretimine dayalı yeni bir derin öğrenme yaklaşımı önermişlerdir. (Kanaeva and Ivanova, 2021)

Baygın ve arkadaşları otomatik asfalt arıza tespitine yönelik bir yöntem geliştirmiş, yol yüzeylerinden elde edilen 3912 adet görüntü ile veri seti oluşturmuşlardır. Görüntü işleme yapılması sonucunda sağlam ve bozulma görüntülerin sınıflandırılmasını hedeflemişlerdir. Boyutları indirgenen fotoğraflar asfalt kaplamanın durumunun incelenmesine yönelik otomatik ve yüksek doğruluklu bir yöntem geliştirildiği bildirilmiştir, çalışma sonucunda %96,5 doğruluk yakalanmıştır (Baygın vd, 2021).

Mohan ve Poobal beton yüzeyindeki çatlakların manuel denetimini, çatlak denetimi için kabul gören bir yöntem olduğunu, çatlağın krokisi manuel olarak hazırlandığını ve düzensizliklerin koşullarının not edildiğini ve tamamen uzmanın bilgi ve deneyimine bağlı

olduğundan, nicel analizde nesnellikten yoksun olduğunu dile getirmişlerdir. Bu nedenle, otomatik görüntü tabanlı çatlak tespiti alternatif bir yöntem olarak önerilmiştir. Çalışmalarında, araştırma zorluklarını ve bu alanda elde edilen başarıları belirlemek için ayrıntılı bir anket yapmışlar, çatlak tespiti ile ilgili 50 araştırma makalesini incelemişlerdir. İncelemeye dayanarak, görüntü işleme tekniklerine, hedeflere, doğruluk seviyesine, hata seviyesine ve görüntü veri setlerine göre analiz sağlanmıştır. Araştırmacıların çatlak tespiti üzerine daha fazla çalışma yapmaları için faydalı olabilecek çeşitli araştırma konuları sunulmuştur. (Mohan and Poobal,2017)

Deveci ve arkadaşları gerçek otoyoldan elde ettikleri 1500 adet görüntü ile oluşturdukları veri setini eğitim ve test verisi olarak kullanmışlardır. Fotoğraflar en boy oranı eşit olacak şekilde boyutları düşürülmüştür. Mevcut veri seti eğitim ve test verisi olarak bölünmüş, her iki gruptaki görüntüler normal ve hasarlı olarak sınıflandırılmıştır. Akabinde 1,2 ve 3 bloklu VGG-16 mimarisi kullanmak suretiyle %83,988, %83,988 ve %95,930 değerleri elde etmişlerdir. Tahmin amacıyla ilgili resim ve kod yapısı teşkil edildikten sonra oluşturulan modelin seçilen resmin çatlak içerip içermediğini tahmin etmesini sağlamışlar ve eğitilen model tahminde başarılı olmuştur. (Deveci ve Ergen, 2021)

- **Görüntü Segmentasyonu:** Bilgisayarla görme algoritmaları, yol yüzeyindeki kusurları tespit etmek için görüntü segmentasyonu tekniklerini kullanır. Bu teknik, yol yüzeyindeki farklı nesneleri veya alanları belirleyip sınıflandırarak çatlak, çukur, su birikintisi gibi kusurları ayırabilmektedir. Son yıllarda tespit edilen deformasyon görüntülerini işlemek ve akabinde bakım değerlendirmemelerini ve ihtiyaçlarını oluşturmak için bilgisayarla görme algoritmaları kullanılmaya başlanmıştır (Deveci vd, 2021).
- **Kenar Tespiti:** Kenar tespiti algoritmaları, görüntüdeki ani parlaklık veya renk değişikliklerini analiz ederek yol yüzeyindeki çatlakları, kırıkları veya diğer bozulmaları algılar. Bu algoritmalar, kusurlu bölgeleri hassas bir şekilde sınırlandırır.
- **Özellik Çıkarma ve Desen Tanıma:** Bilgisayarla görme teknikleri, görüntülerdeki belirli desenleri ve özellikleri analiz ederek kusurları sınıflandırır. Örneğin, bir çukur, çatlak veya yol aşınması gibi farklı kusur türlerini tespit edebilir.

#### *Yapay zeka ve makine öğrenmesi*

Yapay zekanın en önemli alanlarından birisi olan makine öğrenmesi bilgisayarın herhangi bir olay ile ilgili bilgi ve deneyimleri öğrenerek gerçekleşmesi muhtemel olaylara dair

karar verme ve çözüm üretebilme yeteneği olarak tanımlanabilir. Buradaki ana unsur girdi ve çıktılarının ilişkilendirilmesidir (Öztemel,2022).

- **Derin Öğrenme Modelleri:** Derin öğrenme, özellikle sinir ağları (neural networks) yoluyla büyük veri kümeleri üzerinde eğitilerek yol kusurlarını tanımayı öğrenebilen bir makine öğrenmesi türüdür. Özellik çıkarma ve dönüştürme işlemi için birçok doğrusal olmayan işlem birimi katmanını kullanır. Ardışık katmanlar bir önceki katmanın çıktısını girdi olarak işleme alır (Şeker vd, 2017).

Çatlak tespitinde geleneksel yaklaşımın manuel tespit yöntemleri olduğu daha önce bahsedilmişti. Kaplamalı sahaların büyüklüğü göz önüne alınırsa, kaplama kusurlarını tespit edecek etkili bir aracı teşkil etmek teknolojinin bu alana dahil olması açısından önemlidir. Bu sayede, mevcut yol durumunun izlenmesi için gereken süre büyük ölçüde azalacaktır. Son yıllarda yollarda görülen bozulmaların tespiti ve değerlendirilmesi için birçok bilgisayar destekli ve yapay zeka destekli pek çok çalışma önerilmiştir.

Birçok kaplamalı yüzey kusuru sınıflandırma sistemi, binlerce etiketlenmiş yol görüntüsü kullanılarak eğitilen derin öğrenme modellerine dayanmaktadır. Kaplamalı yüzey durumu analizlerinin yapay zeka kullanımıyla otomatik bir şekilde gerçekleştirilmesi, bilgisayarla görme yöntemlerinin pratik uygulaması için güncel ve yaygın bir eğilimdir.

- **Kusur Türlerinin Sınıflandırılması:** Yapay zeka algoritmaları, çatlaklar, çukurlar, asfalt bozulmaları ve aşınmalar gibi çeşitli kusur türlerini ayırt edebilir. Bu sistemler, kusurların boyutunu, derinliğini ve ciddiyetini de analiz ederek yol bakım önceliklerini belirleyebilir.
- **Özelleşmiş Veri Kümeleri:** Makine öğrenmesi algoritmaları, her yol tipine, malzemeye veya bölgesel faktöre özgü veri kümeleriyle eğitilerek daha doğru sonuçlar verebilir. Özellikle bölgesel iklim ve çevre koşullarının yol üzerindeki etkileri analiz edilebilir.

#### *Gerçek zamanlı yol taraması*

- **Mobil Görüntüleme Sistemleri:** Görüntü analiz sistemleri, hareket halindeki araçlara monte edilmiş kameralar ya da mobil cihazlar aracılığıyla gerçek zamanlı olarak yol yüzeyini tarar. Tespit esnasında konum bilgisi alınmasını mümkün kılar.

Soytürk ve arkadaşları yol yüzeyinde bulunan ve kazlara neden olabilecek tümsek ve çukurların tespitinde ivme algılayıcı cihaz ve GPS kullanmak suretiyle hasarlı bölgelerin lokasyonu ile tespit edilebileceğini, sisteme bütünleşmiş bir depolama birimi ile elde edilen verilerin daha sonra incelenmek üzere saklanabileceğini öne sürmüşlerdir. (Soytürk vd.,2014)

- **Gerçek Zamanlı Kusur Tespiti:** Toplanan görüntüler, aynı anda işlenerek yol kusurları tespit edilir ve bu sayede bakım ekiplerine hızlıca geri bildirim sağlanır. Anında alınan bu veriler, yol trafiğini etkilemeden hızlı müdahale imkanı tanır.

Görüntü analiz yöntemlerinin en büyük avantajı geniş yol ağlarını ve kaplamalı sahaları kısa sürede tarayabilmesi, böylece yolların kapatılmasına gerek kalmadan kusur tespiti yapılabilmesi olarak dile getirilebilir. Görüntü analiz sistemlerinin milimetre düzeyinde hassasiyete sahip olması nedeniyle küçük kusurları bile algılayabilmesi, yapay zeka tabanlı sistemlerin otomatik olarak çalışabilmesi ve sürekli veri toplayarak güncel yol durumu hakkında bilgi sağlaması, yüksek hızlı kameralar ve analiz sistemlerini, yoldaki kusurları anında tespit ederek hızlı müdahaleyi mümkün kılması olarak sıralanabilir.

Görüntü Analiz Yöntemlerinin Dezavantajlarından bahsetmek gerekirse yüksek çözünürlüklü kameraların ürettiği büyük veri setleri, güçlü donanım ve sofistike yazılım gerektirir. Bu da maliyet ve altyapı gereksinimlerinin artırması açısından en büyük handikap olarak değerlendirilebilir. Bunun yanı sıra kötü hava koşulları (yağmur, kar, sis), ışık durumu, gölgeler kamera görüntülerinin kalitesini etkileyebilir ve kusurların tespitini zorlaştırabilir. Yapay zeka modellerinin doğru şekilde eğitilmesi için geniş ve çeşitli veri setlerine ihtiyaç duyulur. Verilerin kalitesi model performansını doğrudan etkiler, bu nedenle veri toplama ve veri açıklamasıyla ilgili en iyi uygulamaları anlamak önemlidir. Veri setlerinin işlenmesi ve sonuçların alınması için yapay zeka alanında uzman ekip arkadaşlarını gerektirir. Bölgesel farklılıklar, farklı yol malzemeleri veya iklim koşulları, modellerin performansını etkileyebilir.

### ***Akustik yöntemler***

Akustik yöntemler kullanarak deformasyon tespitinde yüzeye darbe, titreşim veya yüksek frekanslı ses dalgaları göndermek suretiyle yankıların dinlenmesi ve analiz edilmesiyle yüzey altı kusurları tespit edilebildiği yöntemlerdir. Basınç, yük veya sıcaklık değişiklikleri gibi dış uyaranların neden olduğu yapısal yorgunluk ve bozulmayı tespit etmek için uygun tahribatsız bir test metodudur. Test edilen malzemeye uygulanan ses dalgası, malzemenin yoğunluğunda bir değişiklikte karşılaştığında bozulur ve iletilen dalgadaki bu değişiklik bir alıcı tarafından yakalanır. Test cihazı alınan dalgayı ölçer ve analiz eder, elde ettiği verilerle kusurun doğasını ve derinliğini tespit etmektedir. Test cihazları ayrıca malzemedeki dalga hızını seyahat için geçen zamana bölerek numunenin kalınlığını da hesaplayabilmektedir (Prokopets, 2025).

Özellikle boşluklar ve yüzey altındaki ayrışmalar bu yöntemle ortaya çıkarılabilmektedir. Yüzey altında bulunan ve gözle görülmesi zor olan kusurların tespitinde

etkili bir yöntem olmakla beraber uygulaması zor ve verilerin yorumlanması için uzmanlık gerektirmektedir.

1. Ultrasonik Dalga Yöntemi
2. Yüzey Dalga Analizi
3. Titreşim Analizi
4. Yeraltı Kusurlarının Tespiti
5. Geoteknik Akustik Sensörler
6. Sesin Yansıma ve Soğurulma Analizi
7. Akustik Emisyon Yöntemi

Akustik Yöntemlerin Avantajlarından bahsedecek olursak sadece yüzeydeki değil, yüzeyin altındaki kusurları da tespit edilebilir. Bu, diğer yöntemlerle tespit edilemeyen derin çatlaklar veya boşlukların belirlenmesine olanak tanır. Akustik yöntemler, yol yüzeyine doğrudan temas gerektirmeyen tahribatsız bir test yöntemidir ve hızlı veri toplayabilir. Yoldaki kusurlar, trafiğin aksamasına mahal vermeden tespit edilebilir. Akustik sensörler kullanılarak yolların yapısal durumu sürekli izlenebilir. Bu, yol kusurlarının erken aşamada tespit edilmesine ve zamanında müdahale edilmesine olanak tanımaktadır.

Akustik Yöntemlerin Dezavantajlarından en kritiği hassas ve pahalı ekipmanlar gerektirmesi, bu tür cihazların kurulum ve bakım maliyetleri yüksek olması, ulaşımı zor olan ve çok yaygın olmayan cihazlar olmasıdır. Akustik sinyallerin analizi karmaşıktır ve uzmanlık gerektirir. Yüzeydeki farklı malzemeler, sesin yayılımını ve yansımasını etkileyebilir, bu da analiz sürecini zorlaştırabilir. Özellikle yoğun trafik veya inşaat gibi çevresel gürültüler, akustik sinyallerin doğruluğunu olumsuz etkileyebilir.

#### *Titreşim ölçümleri*

Araçlar veya ekipmanlar pist üzerinde hareket ettirilerek titreşim verileri toplanır ve bu veriler analiz edilerek yüzey kusurları tespit edilir. Kaplamalı sahalardaki mikro deformasyonların belirlenmesinde etkilidir. Analizlerin doğru yapılabilmesi için özel yazılım ve uzmanlık gerektirir (Soytürk *et al.*2014).

1. Titreşim Sensörleri (Akustik Sensörler ve İvmeölçerler)
2. Titreşim Frekansı ve Genlik Analizi
3. Araç Tabanlı Titreşim Ölçümü
4. Yüzeydeki Kusurların Titreşim Desenleri
5. Sürekli Titreşim İzleme
6. Gelişmiş Titreşim Analizi Yöntemleri

Titreřim sensörleri, yol yüzeyindeki küçük kusurları bile algılayabilecek kadar hassas olabilir. Bu sayede yolun bozulma süreci erkenden izlenebilir. Titreřim ölçümleri, yola doğrudan müdahale gerektirmeden yapılabilir ve hızlı sonuçlar sağlar. Araç hareketi sırasında bile ölçüm yapılabilmesi, trafiğin kesilmesine gerek bırakmaz. Sabit sensörler veya araç tabanlı sistemlerle sürekli titreřim izleme yapılabilir. Bu, yol yüzeyinin zaman içindeki yapısal deęişikliklerinin sürekli olarak izlenmesini sağlar.

Titreřim ölçümleri, çevresel gürültü ve titreřimlerden etkilenebilir. Özellikle yoğun trafik veya inřaat gibi dış etkenler, titreřim verilerinin doğruluęunu olumsuz etkileyebilir. Titreřim verilerinin doğru bir şekilde yorumlanması için uzmanlık gerektirir. Yolun yapısına, malzemesine ve dięer faktörlere göre titreřimlerin analiz edilmesi karmařık olabilir. Titreřim ölçüm cihazları ve sensörleri, gelişmiş ve maliyetli donanımlar gerektirebilir. Bu cihazların kurulum ve bakımı maliyetli olabilir.

## MATERYAL VE METOD

### Materyal

Bu çalışmada havaalanı kaplamalı saha yüzeylerinde (pist, apron ve taksi yolları) meydana gelen yüzey kusurlarını tespit edebilmek amacıyla özgün bir görüntü veri seti oluşturulmuştur. Veri seti, Türkiye'nin çeşitli havaalanlarında farklı iklim ve çevresel koşullarda, doğal saha ortamlarında çekilmiş görüntülerden oluşmaktadır. Görüntülerin elde edilmesinde, taşınabilirliği ve yüksek çözünürlüklü kamerası nedeniyle iPhone 11 marka mobil cihaz tercih edilmiştir. Böylece saha koşullarında pratik bir şekilde yüksek kaliteli görüntülerin toplanması mümkün olmuştur.

Toplamda 1000 adet görüntü toplanmıştır. Bu görüntülerin 650 adedi hasarsız, yani yüzey deformasyonu içermeyen sağlıklı alanları temsil ederken, 350 adedi yüzey deformasyonu (çatlak, soyulma, kırılma, yama) içeren örnekleri kapsamaktadır. Görüntüler, gündüz saatlerinde ve yeterli doğal aydınlatma koşulları altında çekilmiş; böylece modelin eğitimi için görsel açıdan tutarlı ve net veri sağlanması hedeflenmiştir.


### Metot

Bu çalışmada, havaalanı kaplamalı saha yüzeylerinde meydana gelen çatlak ve benzeri yüzey kusurlarının otomatik olarak tespit edilmesi amacıyla, derin öğrenme temelli bir yaklaşıma başvurulmuştur. Oluşturulan görüntü veri setleri, günümüzde en yaygın ve etkili derin öğrenme yöntemlerinden biri olan Evrişimsel Sinir Ağları (CNN) aracılığıyla işlenmiştir. Bu kapsamda, yüksek doğrulukla nesne tespiti yapabilen CNN tabanlı YOLOv11 (You Only Look Once) mimarisi tercih edilmiş ve eğitim süreci bu model üzerinden yürütülmüştür. Doğruluk oranının yüksekliği ve hızlı olması nedeniyle YOLOv11 algoritması tercih edilmiştir.

2024 yılında resmi tanıtımı yapılan YOLOv11'in, önceki nesillere kıyasla daha hızlı ve daha doğru çalıştığı bilinmektedir. Bu yeni versiyon nesne görüntü sınıflandırma, örnek segmentasyonu ve algılama gibi YOLOv8 versiyonunun sunduğu bilgisayarla görme görevlerini yerine getirebilmektedir. YOLOv11, optimize edilmiş mimarisi ve ölçeklenebilir yapısı sayesinde, sınırlı donanım kaynaklarına sahip gömülü ve uç cihazlardan yüksek işlem kapasitesine sahip bulut tabanlı sistemlere kadar uzanan geniş bir yelpazedeki bilgi işlem gereksinimlerini karşılayabilecek biçimde tasarlanmıştır. Söz konusu model, araştırma ve

geliştirme faaliyetlerine yönelik açık kaynak kodlu bir sürümün yanı sıra, endüstriyel uygulamalar için optimize edilmiş kurumsal bir sürümle de sunulmaktadır. (Vina, 2025)

YOLO11 mimarisi, performans ve verimlilik odaklı tasarımıyla nesne algılama alanında öne çıkmaktadır. Model, son tahmin katmanlarında hız optimizasyonuna odaklanan algılama başlığı sayesinde minimum gecikme süresiyle yüksek hızlı çıkarımlar gerçekleştirebilmektedir. Ayrıca optimize edilmiş omurga (backbone) ve boyun (neck) yapısı, özellik çıkarım kapasitesini artırarak daha kesin ve güvenilir tahminler yapılmasını sağlamaktadır. Bununla birlikte YOLO11, uç cihazlardan bulut tabanlı platformlara ve NVIDIA GPU tabanlı sistemlere kadar geniş bir yelpazedeki bilgi işlem ortamlarında verimli bir şekilde çalışabilecek biçimde optimize edilmiştir. Bu sayede model, farklı donanım ve yazılım altyapılarına sorunsuz bir şekilde entegre edilebilmektedir. . (Vina, 2025)



Şekil 40. YOLO Versiyonlarının COCO veri kümesi üzerinden karşılaştırması (Vina, 2025)

#### Mimari yenilikler ve temel yapı

- C3k2 Bloğu: YOLOv11, önceki modellerde kullandığı C2f bloğunu, daha verimli olan C3k2 bloğuyla değiştirilmiştir. Bu, tek büyük konvolüsyon yerine iki küçük konvolüsyon kullanıp işlemi hızlandırıyor ve hesap yükünü azaltmaktadır.
- SPPF ve C2PSA Bileşenleri: SPPF (Spatial Pyramid Pooling – Fast) bloğu korunurken, bunun ardından C2PSA (Cross Stage Partial with Spatial Attention) bloğu eklenmiştir. Bu, modelin önemli bölgelere dikkatini artırarak hem doğruluğu hem de küçük veya karmaşık nesnelerin tanınmasını iyileştirmektedir.
- Kod Tabanı Uyumu: YOLOv11, YOLOv8 kod tabanını sürdürerek mimari yenilikleri bu altyapı üzerine entegre etmiştir. (Ghosh,2025)

### **Parametre verimliliği, hız ve maliyet**

- Daha Az Parametre, Daha Fazla Başarı: Örneğin, YOLO11m versiyonu, YOLOv8m'ye kıyasla yaklaşık %22 daha az parametreyle daha yüksek mAP (mean Average Precision) sunmaktadır.
- Hızda İyileştirme: Latency (gecikme süresi) açısından önemli kazanımlar sağlanmıştır. GPU optimizasyonları sayesinde bazı durumlarda %25'e kadar daha az gecikme süresi elde edilebilmektedir. Bu durum gerçek zamanlı uygulamalar için idealdir. (Vina, 2025)

### **Görev çeşitliliği ve esneklik**

YOLOv11; tek bir model ailesi içinde nesne algılama (detection), örnek-segmentation (instance segmentation), poz tahmini (pose estimation), döndürülmüş sınır kutuları (oriented bounding boxes – OBB) ve sınıflandırma (classification) görevlerini desteklemektedir. Bu, önceki modellerde bulunan desteği daha geniş ve kapsamlı hale getirmektedir. (Mukherjee, 2024)

### **Doğrudan performans karşılaştırmaları**

YOLOv8, v9, v10 ve v11 eş koşulla bir trafik video setinde karşılaştırılmıştır. YOLOv11, hem büyük araçları (ör. kamyonları) tespit etmede hem de küçük, uzaktaki araçları tanımada dikkat çekici gelişme göstermiştir. Hız açısından tüm modeller 10–20 ms arasında çalışarak 50+ FPS seviyelerinde performans göstermiş; ancak YOLOv11 en iyi hız-doğruluk dengesi sunmuştur. (Vina, 2025)

İleriki bölümlerde, veri toplama süreci, model eğitimi, hiperparametre ayarları ve performans değerlendirme ölçütleri detaylı olarak açıklanmıştır.

### **Makine öğrenmesi**

Yapay zeka (AI-Artificial Intelligence) günümüzde üzerinde en çok konuşulan, tartışılan ve çalışılan konuların başında gelmektedir. Çok kaba bir tabirle yapay zeka, bir bilgisayarın veya bilgisayar tarafından kontrol edilen bir robotun, zekâ gerektiren akıl yürütme, genelleme, yorum yapma ya da geçmiş deneyimler vasıtasıyla öğrenme, şekilleri ya da görselleri tanıyabilme gibi görevleri insan benzeri bir şekilde yerine getirme yeteneğidir. Yapay zekanın en önemli alanlarından birisi olan makine öğrenmesi ise bilgisayarın eğitilerek karar verme ve çözüm üretebilme yeteneği kazanması olarak adlandırılabilir (Öztemel, 2022).

Daha 1950 yılının başlarında makineler düşünebilir mi sorusunun cevabı tartışılırken ve bu konuda ciddi girişimler varken bu soru çok kısa sürede yanıt bulmuş, 1956 yılına


gelindiğinde John McCarthy Dartmouth Görüşmesi kapsamında “Yapay Zeka (Artificial Intelligence -AI)” kavramını insanlık tarihine kazandırmıştır (Özgür,2021).

21’inci yüzyıla gelindiğinde yapay zeka uygulamaları ve teknolojileri hayatımıza hızlı bir giriş yapmıştır. Geline durum itibariyle yapay zekanın günlük hayatımızda kapladığı hacim her geçen gün daha da hızlı bir şekilde artmaya devam etmektedir. Yapay Zeka Gelişmelerinin Tarihsel İlerleyişi Şekil 41’de sembolize edilmiştir.

Çok büyük ve karmaşık verilerin analiz edilmesi, yorumlanması ve doğru neticelere ulaşılması mühendisliğin temel problemlerinden birisiyken, yapay zeka teknolojilerindeki hızlı ilerleyiş bu konudaki problemlerin çözümüne büyük katkıda bulunmuştur.

Yapay zekânın kalbi ve bir alt dalı olarak tarif edebileceğimiz makine öğrenmesi (machine learning), 1950 yılında Alan Turing ve 1952 yılında IBM çalışanı Arthur Samuel'in ortaya koyduğu tezle hayatımıza girmiştir (Akın ve Şahin, 2023). Alan Turing'in "Can machines think?" sorusu çok kısa sürede cevap bulacaktır.

Makine öğrenmesi bilgisayarların direkt programlanmadan, temelde bazı istatistiksel işlemler ve önceki bilgileri kullanarak elimizdeki verilerden anlamlı çıkarımlar yaparak tahminde bulunan ve bu doğrultuda sürekli gelişip öğrenmeyi sağlayan bir bilgisayar algoritması ve yapay zekâ alt dalıdır. Bir başka tabirle bir makinenin sert kodlanmış kurallar yerine büyük veri setlerini kullanmayı öğrenmesini ifade eder. Sistem, deneyimle (veriyle) gelişir ve örüntüleri tanımayı, tahminler yapmayı öğrenir (Türkmen,2021).



**Şekil 41.** Yapay zeka gelişmelerinin tarihsel ilerleyişi (Akın ve Şahin, 2023)

Makine öğrenmesinin ilerleme metodolojisini basitçe aşağıdaki gibi gösterebiliriz.

[Makine öğrenmesi = Veri + Algoritmalar + Deneyim] ➡ Öğrenme

Makine öğrenmesi tahmin sistemleri (hava durumu, finans), tavsiye motorları (Netflix, Spotify), medikal teşhis sistemleri, otomatik çeviri, sürücüsüz araçlar (otonom sürüş) resim ve

ses tanıma teknolojileri ile robot teknolojileri gibi pek çok alanda yoğun bir şekilde kullanılmaktadır (Özgür,2021).

Veriye dayalı karar alma süreçlerinde kritik faktörleri takip etmek, bu verileri belirli problemlere uyarlamak ve analiz yaparak çıkarımlara ulaşmak zaman zaman oldukça zorlaşabilir ve bu durum insan kapasitesinin yetersiz kalmasına neden olabilir. Bu gibi durumlarda yani büyük ölçekli veriler söz konusu olduğunda mekanik öğrenme metotları analiz ve sonuç alma sürecini çok daha kolaylaştırabilir.

Makine öğrenmesinin veriler arasındaki ilişkiyi tanımlayabilmesi veya karar vermeyi otomatikleştirebilmesi makine öğrenimini son derece değerli bir araç haline getirmiştir. Makine öğreniminin, farklı sektörlerde çalışmaları daha hızlı ve verimli hale getirerek zaman ve maliyet tasarrufu sağladığını da açıkça görülmektedir.

Chatterjee ve arkadaşları çalışmalarında farklı koşullar altında sürücünün bakış açısından çekilen önden görünüm görüntülerini kullanarak yol yüzeylerinde çatlak ve ilgili kusur tespiti zorluğunun üstesinden gelmek için makine öğrenimi tabanlı bir yaklaşım önermişlerdir. Öncelikle yol görüntülerini daha küçük uyumlu görüntü bölgelerine işlemek için süperpiksel tabanlı bir yöntem kullanmışlar, bu süper pikseller daha sonra çatlak ve çatlak olmayan bölgeler olarak sınıflandırılmıştır. Gradient Boosting, Yapay Sinir Ağı, Rastgele Orman ve Doğrusal Destek Vektör Makineleri gibi sınıflandırıcılar bu görev için değerlendirilmiştir. Gerçek veri kümeleri üzerinde yapılan değerlendirmeler, yaklaşımın farklı yol yüzeyi koşullarını ve çatlak türlerini başarıyla ele aldığını ve sahne görüntülerindeki kusurlu bölgeleri bulduğunu bildirmişlerdir (Chatterjee *et al.* 2018).


### **Derin öğrenme (Deep learning)**

Derin öğrenme (deep learning), büyük veri kümelerinden öğrenebilen yapay sinir ağlarını kullanarak veriden karmaşık örüntüleri öğrenmeyi sağlayan yapay zekâ ve makine öğrenmesinin (ML) bir alt dalıdır. Yapay sinir ağları, insan beyninin çalışma yapısını taklit edecek şekilde tasarlanmış algoritmalar ve özellikle büyük veri ile yüksek hesaplama gücüne ihtiyaç duyarlar. Manuel özellik çıkarımı yerine, veriden otomatik olarak özellikleri öğrenirler.

Basit bir ifadeyle derin öğrenme; Şekil 42’de görüldüğü gibi çok sayıda katmandan oluşan sinir ağlarını ifade eder. Katmanlar bir önceki katmanın çıktısını girdi olarak kullanır (Şeker vd,2017).

Bu ağlar, fotoğraflar, sesler gibi gözlemsel verileri işlemek ve anlamlandırmak için kullanılır. Süreç ham verilerin giriş katmanından geçmesiyle başlamakla beraber gerçek öğrenmenin gerçekleştiği çoklu gizli katmanlara gelir. Birbirine bağlı düğümlerden oluşan

katmanlar boyunca ilerler. Her bir düğüm, gelen veri üzerinde matematiksel işlemler gerçekleştirir ve işlenmiş bilgiyi bir sonraki katmana aktarır. Her katman, bir öncekine göre daha karmaşık ve soyut özellikleri öğrenir; bu süreç, nihai çıktıya ulaşılan kadar devam eder. Çıktı katmanı tüm bu işlemler temelinde sonuçlar veya tahminler üreterek süreci sonlandırır.



**Şekil 42.** Yapay sinir ağı

Derin öğrenme yöntemleri, büyük veri kümelerini işleyerek karmaşık örüntüleri öğrenme yeteneği sayesinde sağlık hizmetlerinden eğitime, üretimden ulaşım, finansal hizmetlerden robotik ve doğal dil işlemeye kadar birçok alanda yaygın olarak kullanılmaktadır. Sağlıkta özellikle tıbbi görüntüleme alanında hastalık tespiti ve teşhisinde yüksek doğruluk sunarken (Ravi *et al.* 2017; Li *et al.* 2022), eğitimde bireyselleştirilmiş öğrenme sistemlerine katkı sağlamaktadır (Cao and Sun, 2024). Endüstriyel uygulamalarda kalite kontrol ve kusur tespitinde, üretim hatlarının verimliliğini artırmak için derin öğrenme tekniklerinden faydalanılmaktadır (Czimmermann *et al.* 2020; Perez *et al.* 2019; Shi *et al.* 2017). Ulaşımında otonom araçların gelişimini desteklerken (Kang and Cha, 2018), finansal hizmetlerde risk analizi ve dolandırıcılık tespitinde etkin rol oynamaktadır (Kumar *et al.* 2017). Robotikte nesne tanıma ve manipülasyon gibi görevlerde kullanılarak otomasyonu güçlendirmekte (Su, 2024), doğal dil işlemeye insan dilini analiz ve sentez edebilmektedir (LeCun *et al.* 2015). Tarımda ise mahsul izleme ve hastalık teşhisi gibi uygulamalarda sürdürülebilirliği desteklemektedir (K and Krishna, 2024). Tüm bu alanlardaki başarısı, derin öğrenme yöntemlerinin ulaştırma mühendisliğinde, özellikle havaalanı kaplamalı sahalardaki bozulmaların nedenlerini analiz etmek ve önleyici stratejiler geliştirmek amacıyla da etkin biçimde kullanılabileceğini göstermektedir.

Derin öğrenme (DL) modelleri, büyük ve çeşitli veri kümeleri kullanılarak kapsamlı bir eğitim süreci gerektirir. Uygulama çalışmak için insanoğlu tarafından tasarlanmış herhangi bir kurala ihtiyaç duymaz; bunun yerine, verilen girdiyi belirli etiketlerle eşleştirmek için büyük miktarda veri kullanır. Derin öğrenme, her biri kendilerine beslenen verilerin farklı bir yorumunu sağlayan çok sayıda algoritma katmanı (yapay sinir ağları veya YSA'lar) kullanılarak tasarlanmıştır. DL, geleneksel makine öğrenmesi yöntemlerinin aksine, çeşitli görevler için özellik kümelerinin öğrenilmesini otomatikleştirme yeteneğine sahiptir. DL, öğrenme ve

sınıflandırmanın tek bir seferde gerçekleştirilmesini sağlar ve büyük verilerin işlemindeki gelişimi nedeniyle son yıllarda inanılmaz derecede popüler bir makine öğrenimi algoritması türü haline gelmiştir. Çeşitli makine öğrenimi görevleri için yeni performans açısından hala sürekli gelişim halindedir ve görüntü çözünürlüğü, nesne algılama ve görüntü tanıma gibi birçok öğrenme alanının geliştirilmesini kolaylaştırmıştır. Son zamanlarda, DL performansı görüntü sınıflandırma gibi görevlerde insan performansını aşmaya başlamıştır (Alzubaidi *et al.* 2021).

Sahip olduğu becerilerle makine öğrenmesinden farklı olmakla beraber temelde derin öğrenme, makine öğrenmesinin bir alt dalıdır. Makine öğrenmesi algoritmaları yanlış bir tahmin yaptığında, genellikle bir uzmanın müdahale edip modeli yeniden düzenlemesi gerekir. Buna karşılık, derin öğrenme algoritmaları tahminlerinin doğruluğunu kendi başlarına değerlendirebilir ve hatalarından öğrenerek performanslarını iyileştirebilir. Bu yöntemlerde, bilgisayara bir veri kümesi verilir ve bilgisayar bu veriler üzerinden öğrenerek genelleme yapmayı başarır.

Derin öğrenme, son 15 yılda endüstri standartlarında önemli bir üstünlük sağlamış ve yapay zekâ alanında geniş çapta kabul görmeye başlamıştır. Derin öğrenmenin bu başarısı, yapay zekâyâ olan ilgi ve araştırmalarda kullanılacak finansmanda büyük bir artışı beraberinde getirmiştir. Bilim dünyasındaki popüleritesi 2012 yılına denk gelir. Krizhevsky ve arkadaşları nesne tanımlama alanında en önemli sahne olan Büyük Ölçekli Görsel Tanıma Yarışmasını (ImageNet-Competition 2012) o yıl derin öğrenmede temel mimari kabul edilen Evrimsel Sinir Ağı (ESA) ile kazandı (İnik ve Ülker, 2017).

Derin öğrenme ve makine öğrenmesi yaklaşımları arasındaki temel kavramsal ve yapısal farklar Tablo 5'te karşılaştırmalı olarak sunulmuştur.

Derin sinir ağları (DNN'ler) belirli üstyapı sıkıntı türlerini tanımada faydalı olduklarını göstermiştir. Gagliardi ve arkadaşları tarafından yürütülen araştırma, gerçek zamanlı nesne tespiti için YOLO (You Only Look Once) gibi DNN mimarilerini kullanmaya odaklanmış ve kaldırımlardaki çeşitli sıkıntı türlerinin tanımlanmasını kolaylaştırmıştır. Bulguları, semantik segmentasyonun dahil edilmesinin koşulların daha hassas bir şekilde değerlendirilmesine yol açabileceğini göstermektedir (Gagliardi vd., 2023). Bu özellik, onarım ihtiyaçlarının ayrıntılı analizine olanak tanıdığı ve sonuçta hedeflenen bakım müdahalelerine rehberlik ettiği için özellikle faydalıdır.

Üstyapı Durum Endeksi (PCI) yöntemi de derin öğrenme uygulamaları ile geliştirilmiştir. Geleneksel PCI değerlendirmeleri, kapsamlı havalimanları için büyük veri kümelerini analiz etmede sınırlamalara sahiptir, ancak derin öğrenme tekniklerinin

uygulanması, görsel veri girişine dayalı puanlama sürecini otomatikleştirerek bu değerlendirmeleri kolaylaştırabilir. Irvayana ve arkadaşları, bunun özellikle operasyonel güvenlik için zamanında değerlendirmelerin çok önemli olduğu vaka çalışmalarında pist yüzeylerinin gerçek durumunu nasıl etkili bir şekilde yansıtabileceğini göstermiştir (Irvayana vd., 2022).

Derin öğrenmeyi İnsansız Hava Araçları (İHA'lar) ile entegre eden karmaşık modeller de uzak ve erişilmesi zor havaalanı pistleri için uygulanabilir bir yaklaşım olarak ortaya çıkmaya başlamıştır. Yang ve arkadaşları, derin öğrenme algoritmalarıyla donatılmış İHA'ların zorlu coğrafi ve çevresel koşullar altında nasıl ayrıntılı denetimler sağlayabileceğini ve uzak havalimanlarının bile yüksek güvenlik standartlarını ve operasyonel hazırlığı sürdürmesini nasıl sağlayabileceğini araştırmıştır (Yang vd., 2024). Bu durum, derin öğrenme teknolojilerinin havalimanı bakımında çeşitli operasyonel bağlamlara uyarlanabilirliğini göstermektedir.


Havaalanı kaplamalarının değerlendirilmesi ve yönetiminde derin öğrenme tekniklerinin entegrasyonu, havaalanı altyapısının güvenliğini ve dayanıklılığını sağlamada önemli bir ilerleme olarak ortaya çıkmıştır. Derin öğrenme metodolojileri, kaplama koşullarını analiz etmek için görüntü verilerinden ve makine öğrenimi modellerinden yararlanarak erken tespit ve etkili bakım planlaması sağlar; bu da bu tesislere yönelik yüksek operasyonel talepler göz önüne alındığında kritik önem taşır.

Havaalanı üstyapı yönetiminde derin öğrenmenin başlıca uygulamalarından biri, otomatik denetimler için bilgisayarla görme ve makine öğreniminin kullanılmasını içerir. Geleneksel manuel denetimler verimsiz olabilir ve risk oluşturabilir; bu nedenle, derin öğrenme algoritmalarını içeren metodolojiler çatlama, yuvarlanma ve diğer bozulma biçimleri gibi yüzey bozukluklarını tespit etmenin doğruluğunu ve hızını artırabilir (Guo vd., 2021). Örneğin, Guo ve arkadaşları, üstyapı denetimlerini otonom olarak yönlendirmek ve tamamlamak için yapay görme ve derin öğrenmeden yararlanan, böylece denetim sürecini optimize eden ve insan hatasını en aza indiren bir sistem tanıtmıştır (Guo vd., 2021). Bu tür otomatik sistemler yalnızca denetim sürecinin verimliliğini artırmakla kalmaz, aynı zamanda geniş alanlardaki kaplama koşullarının daha kapsamlı bir değerlendirmesini de sağlar (Ibragimov ve ark., 2024).

**Tablo 4.** Derin Öğrenme ile Makine Öğrenmesi Arasındaki Temel Farklar

| Özellik                 | Makine Öğrenmesi         | Derin Öğrenme               |
|-------------------------|--------------------------|-----------------------------|
| Özellik çıkarımı        | İnsan tarafından yapılır | Otomatik olarak öğrenir     |
| Performans              | Orta düzeyde             | Büyük veriyle yüksek başarı |
| Gerekli veri miktarı    | Daha az                  | Çok büyük veri gerektirir   |
| Hesaplama gücü ihtiyacı | Düşük-orta               | Yüksek (GPU/TPU gerektirir) |

Derin öğrenme ile makine öğrenmesi arasındaki temel farklar, görsel olarak karşılaştırmalı olarak Şekil 43’te sunulmuştur.




**Şekil 43.** Derin öğrenme ile makine öğrenmesi arasındaki temel farklar

Yapay sinir ağları oluşturmadaki zorluklardan biri, her bir katman için nöronların sayısının yanı sıra gizli katmanların sayısına karar vermektir. Derin Öğrenmedeki “Derin”, birden fazla gizli katmana sahip olmayı ifade eder. Derin öğrenme uygulamalarındaki bir diğer zorluk bir yapay sinir ağını eğitmektir. Bunun sebebi çok büyük veri kümesine ve çok fazla miktarda hesaplama gücüne ihtiyaç duymasıdır.

En yaygın derin öğrenme metotları:

**Konvolüsyonel Sinir Ağları CNN (Evrşimsel Sinir Ağları):** Bu tür sinir ağları genellikle görüntü işleme için kullanılan çok katmanlı modellerdir. En yaygın kullanılan yapay sinir ağı modelidir. CNN-Evrşimsel sinir ağları giriş katmanı, konvolüsyon, düzleştirme, havuzlama, tam bağlantı katman, DropOut Katmanı ve Sınıflandırma Katmanlarından meydana gelmektedir (İnik ve Ülker, 2017). Şekil 44’te, evrşimsel sinir ağlarının (CNN) genel mimarisi katman yapılarıyla birlikte şematik olarak sunulmaktadır.



**Şekil 44.** Evrşimsel sinir ağı genel mimarisi (WILDML,2016)

1. **RNN (Tekrarlayan Sinir Ağları):** Bu model önceki çıktıları bir sonraki giriş olarak değerlendirerek döngüsel bir yapı oluşturan ve bu döngü süresince bilgileri sıralı bir şekilde işleyen, öğrenme ve tahmine dayalı bir yapay sinir ağı modelidir.

Tekrarlayan sinir ağıları genellikle ses tanıma, altyazı oluşturma, çeviri, uzun metinleri özetleme, videolarda gürültü temizliği, el yazısı tanıma ve metin verileri için kullanılır (Akın ve Şahin, 2023).

2. **LSTM / GRU:** LSTM, bilgileri rastgele zaman aralıklarında hatırlayabilen ve ileri beslemeli sinir ağlarının aksine, geri besleme bağlantılarına sahip olan bir yapay tekrarlayan sinir ağı (RNN) mimarisidir (Mohan and Poobal,2017). Bu model tekrarlayan sinir ağlarına hafızanın ilavesiyle meydana gelen bir modeldir. LSTM bünyesinde hafıza vardır ve bu hücreler önceki durumu ve girdi bilgisini tutma görevini üstlenir. Uzun vadeli bağımlılıkları olan problemler, tahmin yapma veri işleme, zaman serisi verileri ve sınıflandırma gibi amaçlar için kullanılır (Tekin,2023).
3. **Sınırlı Boltzman Makineleri:** Giriş veri setindeki olasılık dağılımlarını öğrenebilen, derin öğrenme ağlarının temelini oluşturan iki katmanlı rastgele yapıya sahip bir yapay sinir ağıdır (Mohan and Poobal,2018). Katmanlar arası bağlantı yoktur. Boyut azaltma, modelleme, sınıflandırma, özellik öğrenimi, regresyon gibi alanlarda kullanılmaktadır (Tekin,2023).
4. **Derin Oto Kodlayıcılar:** Derin oto kodlayıcılar (Autoencoders AE), denetimsiz öğrenme tiplerinde çok sık kullanılan, yapay sinir ağı modelleri arasında yer alan ve denetimsiz öğrenmeye dayalı bir makine öğrenme sistemidir (Tekin,2023). Otomatik kodlayıcılar, boyut indirgeme işleminin yanı sıra veri sıkıştırma, gürültü giderme ve denetimli öğrenme modelleri için öznetelik çıkarma algoritması olarak da kullanılabilir (Akın ve Şahin, 2023).
5. **Derin İnanç Ağları (Deep Belief Network- DBN):** RBM'in geliştirilmiş bir versiyonu olan DBN'ler, veri setinin hiyerarşik temsilini elde etmeyi amaçlayan grafik tabanlı modellerdir. Örüntü tanıma ve üretme konularında yoğun bir şekilde kullanılan model denetimli, denetimsiz ön tanımalı bir sinir ağıdır çeşididir (Tekin,2023).
6. **Uzun-Kısa Süreli Hafıza ( Long Short-Term Memory- LSTM):** Derin öğrenme mimarilerinden biri olan Recurrent Neural Networks (RNN) için özel olarak geliştirilmiş bir hücre türüdür (Tekin,2023).

### **Derin öğrenmenin kullanım alanları**

Derin öğrenme günümüzde hayatın pek çok alanından büyük bir başarı oranıyla kullanılmaktadır. Bunda bilgisayar ve yazılım teknolojilerindeki gelişim, yüksek performanslı işlemciler ve donanımlar sayesinde hesaplama hızı ve verimliliğinin artması önemli paya

sahiptir. Bu sayede büyük ve karmaşık verilerin analizi görece kolaylaşmıştır. Derin öğrenme görüntü işleme, bilgisayarlı görü, medikal, finans ve ekonomi, dil işleme, sinyal işleme, robotik ve otonom sürüş, sosyal medya gibi çok çeşitli alanlarda yoğun olarak kullanılmaktadır (Akın ve Şahin, 2023).

Derin öğrenmenin bazı kullanım alanları aşağıda sıralanmıştır:

**1. Görüntü İşleme ve Bilgisayarlı Görü:** Çeşitli uygulamalarda görüntü tanıma için yaygın olarak kullanılmaktadır. Bilgisayarların görselleri analiz ederek içeriğindeki nesneleri, yüzleri, yazıları veya sahneleri anlamasını sağlayan bir yapay zeka teknolojisidir. Bununla beraber görüntülerin sınıflandırılması, renklendirilmesi, video görüntülere ses ilave edilmesi düşük çözünürlüklü görüntülerin netleştirilmesi veya bozuk görüntülerin düzeltilmesi gibi pek çok alanda yaygın olarak kullanılmaktadır (Doğan ve Türkoğlu, 2018). Derin öğrenme ve sinir ağları sayesinde görüntü işleme alanında çok büyük ilerlemeler kaydedilmiştir. Şekil 45'te, ChromaGAN yöntemi kullanılarak tarihi siyah-beyaz fotoğrafların renklendirilmesi süreci görsel olarak örneklendirilmiştir.



**Şekil 45.** Chroma GAN kullanılarak tarihi siyah beyaz fotoğrafların renklendirmesi (Vitoria et al. 2020)

Genel olarak kullanım alanları:

- **Yüz Tanıma:** Telefon kilidini açma (Face ID), güvenlik sistemleri.
- **Otonom Araçlar:** Yoldaki nesneleri (yayalar, tabelalar) algılama.
- **Sağlık:** Radyoloji ve tıbbi görüntü analizi (örneğin, tümör tespiti).
- **E-ticaret:** Görsel arama (Google Lens, Pinterest Lens).
- **Tarım:** Bitki hastalıklarını tespit etme olarak özetleyebiliriz.

Cao ve arkadaşları çalışmalarında yol çatlaklarının tespitinde kullanılan üç ana yöntem türünü incelemişlerdir: görüntü işleme, makine öğrenimi ve 3D görüntüleme tabanlı yöntemler.

Görüntü işleme algoritmalarının temel olarak görüntüleri işlemek ve çatlak özelliklerini belirlemek için kullanılan eşik segmentasyonu, kenar algılama ve bölge büyütme yöntemlerini içerdiğini belirtmişlerdir. Sinir ağı ve destek vektör makinesi gibi geleneksel makine öğrenimi yöntemlerine dayalı çatlak tespiti, görüntü işleme teknikleri kullanılarak elle oluşturulmuş özelliklere dayandığı, derin öğrenme yöntemlerinin çatlak tespit yöntemini temelden değiştirdiğini ve tespit performansını büyük ölçüde iyileştirdiğini öne sürmüştür. Çatlak tespitinde önerilen derin öğrenme sinir ağlarını sınıflandırma tabanlı, nesne algılama tabanlı ve segmentasyon tabanlı olmak üzere üç şekilde incelemiş ve karşılaştırmışlardır. Performans değerlendirme metriklerini ve bu yöntemlerin yaygın olarak kullanılan kıyaslama veri kümeleri üzerindeki performansını da ele almışlardır. 3D teknolojisinin olgunlaşmasıyla birlikte, 3D veriler kullanılarak çatlak tespitinin yeni bir araştırma ve uygulama alanı olduğu belirtilmiş, üç tür 3B veri temsili karşılaştırmış ve 3B nesne tespiti için derin sinir ağlarının ilgili performansını incelemişlerdir (Cao *et al.* 2020)

2. **Doğal Dil İşleme (NLP):** Dilleri makine dili ve insan dili olarak iki ayrı başlık altında toplayabiliriz. Bilgisayarların insan dillerini anlayabilmesi ve onlarla etkili bir şekilde iletişim kurabilmesi için doğal dil işleme bilimine ihtiyaç vardır. Kısaca, bu süreç bilgisayarların doğal dili anlaması ve işlemesidir. İnsan dilini makinelerin anlayabileceği ve işleyebileceği biçimde analiz etmeye çalışan bir alandır ve derin öğrenme bu alanda devrim yaratmıştır. Yazılı ve sesli işleme olarak iki gruba ayrılır. Günümüzde soru-cevap alanında, pek çok çeviri motorunda yaygın olarak, bir bilginin metin kaynaklarından taranıp bulunması ve getirilmesi maksadıyla, kelime ve metin işleme gibi pek çok alanda başarıyla kullanılmaktadır. Derin öğrenme modelleri, dili hem yapısal hem de anlamsal düzeyde anlamaya çalışır. Bu modeller, büyük veri kümeleri üzerinde kullanılmaktadır. Derin ağlar, nasıl anlayacaklarını ve uygun yanıtları nasıl bulacaklarını öğrenmek için dili okur ve dinler (Seker,2015). Makine çevirisi (Google Translate), metin sınıflandırma ve duygu analizi, chatbotlar ve sanal asistanlar (Siri, ChatGPT), otomatik özetleme ve soru-cevap sistemleri, sesli komut algılama ve yanıt üretme en bilinen kullanım alanlarıdır.
3. **Ses İşleme:** Derin öğrenme mimarilerinin elde ettiği başarılar ve artan popülaritesi, bu sistemlerin ses tanıma alanında da kullanılmasına öncülük etmiştir. Araştırmacılar, ses tanıma ve onun çeşitli uygulamaları örneğin sesle duygu tanıma, ses etkinliği tespiti, konuşmacı tanıma ve doğrulama gibi alanlarda, ses girdileri ile çıktıları arasındaki ilişkilerin daha etkili modellenmesi ve sistemlerin hata

oranlarının azaltılması amacıyla derin öğrenme yaklaşımlarını tercih etmektedir. Konuşma tanıma, metinden sese, ses sentezi ve sesli asistanlar, müzik türü tanıma, ses filtreleme gibi alanlarda kullanılmaktadır (Dokuz ve Tüfekçi,2020).

4. **Robotik-Otonom Sistemler:** Günümüzde en dikkat çeken ve merak edilen alanlardan birisi otonom sistemlerdir. Sürücüsüz araçlar, drone'lar ve robotik sistemler, endüstriyel otomasyon sistemleri alanlarında kullanılmaktadır.

Araştırmacıların ve bu sektörde hizmet veren pek çok şirketin insansı robot tasarlamak ve derin öğrenme temelli metotlarla insana dair yeteneklerin bu robotlara entegrasyonunu sağlamak öncelikli hedeflerindendir (Akın ve Şahin, 2023).

Derin öğrenme, sürücüsüz araç teknolojisinin temel taşlarından birisidir. Bu sistemler, gerçek dünyadaki karmaşık sürüş koşullarını anlamak ve en iyi kararları vermek için büyük miktarda veriyi işlemekte ve hedef lokasyona ulaşmak için emniyetli sürüş stratejisini oluşturmaktadırlar. Özellikle Tesla firması "Tam Otonom Sürüş" (Full Self Driving- FSD) adını verdiği, tamamen elektriksel bileşenlere (kameralar, sensörler) ve yapay zekâya dayalı araçlarını günümüzde piyasaya sunmakta ve bu sistem üzerinde test çalışmalarını sürdürerek yeni güncellemeler geliştirmeye devam etmektedir (Akın ve Şahin, 2023).

5. **Finans ve Ekonomi:** Derin öğrenme, finans ve ekonomi alanlarında büyük bir dönüşüme sebep olmuştur. Finansal analiz, risk yönetimi, algoritmik ticaret, dolandırıcılık tespiti ve daha fazlası için AI ve derin öğrenme teknikleri sıkça kullanılmaktadır. Bu teknolojiler, büyük veri kümelerini hızlı bir şekilde analiz ederek daha doğru ve zamanında kararlar alınmasını sağlamaya yardımcı olur. Hisse senedi, kripto para fiyat tahmini, kredi skorlama ve risk analizi, otomatik yatırım danışmanlığı, dolandırıcılık tespiti gibi işlemlerde kullanılmaktadır (Akın ve Şahin, 2023).
6. **Medikal:** Sağlık sektörü, derin öğrenme ve yapay zeka teknolojilerinden büyük fayda sağlamaktadır. Derin öğrenme algoritmaları kullanarak, insan sağlığını doğrudan etkileyebilecek, teşhis ve tedavilerinde fayda birçok yeni yaklaşım geliştirilmiştir. Sağlık açısından kritik öneme sahip bulgular; sınıflandırma, tespit, görüntü bölütleme ve görüntü üretimi gibi çeşitli işlemlerde etkin bir şekilde kullanılmaktadır (Doğan ve Türkoğlu,2018). Hastalık teşhisleri, tedavi planlaması, genetik veri analizleri, ilaç keşfi ve geliştirme, kişiselleştirilmiş tıp, hasta verisi analiziyle daha hızlı, doğru ve etkili kararlar alınmasını sağlamaktadır.

7. **Araştırma ve Sohbet Programları:** Özellikle ChatGPT hayatımıza hızlı bir giriş yapmıştır. ChatGPT gibi yapay zeka uygulamaları; araştırma, çeviri, slayt, sunum, proje ödevleri gibi birçok konuda çok uzun sürelerde ulaşım sağlanacak dokümanlara ve bilgilere saniyeler içinde erişim imkanı sağlamaktadır. Olağanüstü büyüklükte bir veri havuzuna sahip olan bu sistemler, anbean bilgi dağarcıklarını genişleterek kendi yapay zekâ altyapılarını geliştirmeye devam etmektedir. Ancak bu sistemlerin yararlarının yanında, potansiyel zararları da günümüzün en önemli tartışma konuları arasındadır (Akın ve Şahin, 2023).
8. **Sosyal Medya:** Youtube, Instagram, Facebook, Twitter, TikTok, tanışma uygulamaları ve diğer sosyal medya platformları derin öğrenmeyi çok çeşitli şekilde ve yoğun bir biçimde kullanmaktadır. Beğeneceğinizi düşündükleri içeriklerle önermekten, hakkınızda bildiklerine, aramalarınızda ya da konuşmalarınızda tespit ettiği hususlara yönelik reklamlar sunmaya kadar, bu programlar size insan aklını zorlayan bir deneyim sunmak için hakkınızdaki öğrenme sürecini sürekli devam ettirir. Bu programlar, akıcı ve basit bir deneyim yaşamanıza yardımcı olmak için görüntüler ve girişler için yüz tanıma özelliğini bile kullanır. Tüm bunlar derin öğrenmenin sunduğu gelişimlerdir. Günümüzde herkesin yoğun bir şekilde kullandığı bu uygulamalarda derin öğrenme bizlere şu hizmetlerin sağlanmasına yardımcı olur:
9. **Perakende ve Pazarlama:** Müşteri segmentasyonu, tavsiye sistemleri (Netflix, spotify, Amazon önerileri), satış tahmini ve stok yönetimi, kişiselleştirilmiş reklamcılık gibi alanlarda kullanılmaktadır.
10. **Sanal asistanlar:** Belki de günlük hayatta en çok kullandığımız alanların başında gelir. Aslında Siri veya Google asistan kullandığımızda, derin öğrenen bir sinir ağıyla konuşmuş oluyoruz. Sanal asistan uygulaması, ne istediğinizi anlamak, sesinizi tanımak ve istediğimiz işlemin karşılığını yerine getirmek için konuşma tanıma maksadıyla bu ağı kullanır. Sitem başarısı için sürekli öğrenir ve hesaplar. Bir soruyu cevaplama, bir uygulamayı çalıştırma ya da kapatma, gibi pek çok işlem ve daha fazlası sanal asistanınızdan gelen çıktı yanıtlarıdır.
11. **Eğlence:** Yapay zekâ kontrollü oyun karakterleri, gerçek zamanlı ortam analizi, oyun içi strateji geliştirme gibi alanlarda kullanılmaktadır. Bunun yanı sıra Netflix gibi akış platformları, derin öğrenme ve yapay zeka tabanlı öneri sistemleri sayesinde izleyicilere en uygun içerikleri sunarak kişiselleştirilmiş bir deneyim sağlamaktadır. Netflix size izlemeniz için yeni bir içerik önerdiğinde, sizin beğeni

alanlarınızı ve içerik tercihlerinizi öğrenmek için derin ağlara bakar ve ardından size yeni içerikler tavsiye eder. Derin öğrenme, bu platformlarda kullanıcıların kişiselleştirilmiş bir eğlence deneyimi elde etmelerine yardımcı olur ve uygun içerik arama sürecini kısaltır (Akın ve Şahin, 2023).

### **Derin öğrenme ile görüntü analizi**

Derin öğrenme, görüntü analizi gibi çeşitli görevlerde kullanılmaya başlanan yapay zeka tekniklerinden birisi olduğundan bahsedilmiştir. Görüntü analizi bilgisayarların görselleri ve videoları anlamlandırmasını sağlayan bir yapay zekâ uygulamasıdır. Görüntü işleme teknikleri kullanılarak durağan görüntüler analiz edilebilir ve bu görüntülerden anlamlı bilgiler elde edilebilir.

Derin öğrenme, yapay sinir ağlarının çok katmanlı yapısını kullanarak büyük veri kümelerinden otomatik olarak öğrenebilen modeller oluşturmaktadır. Geniş veri setlerinden özellik çıkarımı yapabilen bu algoritmalar, çok katmanlı mimarilere sahip öğrenme yöntemleri olarak öne çıkar.

Derin öğrenmenin görüntü analizi için kullanılmaya başlanması, bu teknolojinin ilerlemesi ve bilgisayar gücündeki artışla birlikte gerçekleştiği söylenebilir. Özellikle 2010'lu yılların başından itibaren derin öğrenme yöntemleri, görüntü tanıma, nesne tespiti, yüz tanıma gibi görsel işleme problemlerinde büyük başarılar elde etmeye başladı.

2012 yılında gerçekleşen ImageNet Large Scale Visual Recognition Challenge yarışmasında Convolutional Neural Network (CNN) tabanlı bir model olan AlexNet'in büyük bir başarı elde etmesi, derin öğrenmenin görüntü analizindeki önemini ortaya koymuştur. AlexNet'in ILSVRC yarışmasında diğer yöntemlere kıyasla büyük bir başarı elde etmesi, derin öğrenmenin görüntü analizi alanında dönüm noktası olarak kabul edilir (İnik ve Ülker, 2017).

Bu tarihten itibaren derin öğrenme yöntemleri, görüntü analizi alanında hızla yaygınlaşmaya başladı. Bu gelişme, Google, Facebook, Microsoft gibi teknoloji devlerinin derin öğrenmeye yönelmesini tetikledi. Özellikle 2010'lu yılların ortalarından itibaren derin öğrenme modelleri, görüntü sınıflandırma, nesne tespiti, yüz tanıma ve segmentasyon gibi birçok görsel işleme görevinde en iyi sonuçları elde etmeyi başarmıştır. Bugün ChatGPT, DALL·E, Siri, Tesla'nın otonom sürüş sistemi gibi pek çok modern YZ sisteminin temelinde derin öğrenme vardır.

Derin öğrenme katmanlarını kısaca özetlemek gerekirse;

1. **Giriş (Input) Katmanı:** Adından da anlaşılacağı üzere veri giriş katmanı olarak adlandırılır.
2. **Konvolüsyon (Convolution) Katmanı:** Konvolüsyon katmanı sinir ağlarının temelini oluşturur. Bu katman, önceden tanımlanmış bir filtrenin girdi verisi üzerinde kaydırılmasıyla, girdinin belirgin özelliklerini ortaya çıkarmayı amaçlamaktadır. Filtreleme işlemi sonucunda, giriş verisinden boyut olarak daha küçük bir çıktı matrisi elde edilir (Doğan ve Türkoğlu,2018).
3. **Aktivasyon (Relu) Katmanı:** Genellikle konvolüsyon katmanından sonra gelmekle beraber Aktivasyon (ReLU) katmanı, doğrusal olmayanlık kazandırmak amacıyla her bir nöron çıkışına uygulanır. ReLU (Rectified Linear Unit) fonksiyonu, negatif değerleri sıfıra indirirken, pozitif değerleri olduğu gibi geçirerek modelin karmaşık desenleri öğrenmesini kolaylaştırır (Doğan ve Türkoğlu,2018).
4. **Havuzlama (Pooling) Katmanı:** Genellikle ReLU katmanından sonra gelen havuzlama katmanı, verileri özetleyerek boyutlarını azaltır ve böylece ağın sonraki katmanlarına daha düşük boyutlu bir giriş sağlar. Ağda dolaşan veri boyutunun azalması ağın hızının artmasını, hesaplama miktarının azalmasını ve ihtiyaç duyulan bellek miktarının azalmasını sağlar (Doğan ve Türkoğlu,2018).
5. **Tam Bağlı (Full-Connected) Katman:** Bu katmandaki tüm nöronlar, bir dizi (vektör) şeklinde düzenlenmiştir. Tam bağlı katmandaki her bir nöron, bir önceki katmandaki tüm aktivasyonlara bağlıdır. Bu katmanın temel özelliği, önceki katmanlardan gelen özellikleri kullanarak sınıflandırma yapmasıdır. Yani, nesnenin hangi sınıfa ait olduğu, çıkarılan özelliklerin analiz edilmesiyle belirlenir.
6. **Dropout Katmanı:** Çok katmanlı yapay sinir ağlarının eğitimi sırasında, ağın eğitim verisini ezberlemesi anlamına gelen 'aşırı öğrenme' durumu meydana gelebilir. Bu istenmeyen durumun önüne geçmek için, ağdaki bazı nöronların geçici olarak devre dışı bırakıldığı 'dropout' gibi düzenleme yöntemleri kullanılır. Böylece ağ, genelleme yeteneğini artırarak sadece eğitim verisini değil, daha önce görmediği verileri de doğru şekilde tahmin edebilir (Doğan ve Türkoğlu,2018).
7. **Sınıflandırma (Classification) Katmanı:** Son katman olarak tanımlanan ve genellikle tam bağlı katmandan sonra gelen sınıflandırma katmanı, hedef sınıf sayısı kadar çıktı üretir. Her bir çıktı, belirli bir sınıfa ait olma olasılığını temsil eder ve genellikle softmax aktivasyon fonksiyonu kullanılarak bu olasılık dağılımı elde edilir (Doğan ve Türkoğlu,2018).

8. **Yumuşatma (Softmax) Katmanı:** Softmax katmanı, tam bağlı katmandan gelen çıktıları kullanarak her sınıfa ait olasılıkları hesaplar. Bu sayede, modelin bir girdinin hangi sınıfa ait olduğunu tahmin etmesi sağlanır. Üretilen değerler, sınıflara ait olasılık dağılımını temsil eder (Doğan ve Türkoğlu,2018).
9. **Normalizasyon (Normalization) Katmanı:** Derin konvolüsyonel sinir ağlarının eğitimi yüksek hesaplama gücü gerektirdiğinden, eğitim süresini ve aşırı öğrenme riskini azaltmak için 'batch normalization' gibi normalizasyon teknikleri kullanılır. Çoğunlukla ReLU aktivasyonundan sonra uygulanan yumuşatma katmanı, ara katmanlardaki aktivasyonları ortalama ve standart sapma bazında normalize ederek, ağın daha stabil ve verimli öğrenmesini sağlar (Doğan ve Türkoğlu,2018).

Derin öğrenmenin katmanlarından sonra görüntü analizi sürecini kısaca özetlersek:

#### ***Görüntü girişi ve ön işleme aşaması (image pre-processing)***

- Bu aşamada, kameradan elde edilen görüntü üzerinde sırasıyla filtreleme, gri tonlamaya dönüştürme ve ikili (binary) görüntüye çevirme işlemleri uygulanır. Bu işlemler sayesinde, görüntüde yer alan ve analiz edilmek istenen nesneler daha belirgin hale gelir ve işlenmeleri kolaylaşır (Solak ve Altınışık,2017)
- Özelliklerin çıkarılması için çözünürlük ayarlama, filtreleme ve veri artırma (data augmentation) gibi işlemler yapılır.

#### ***Özellik çıkarımı (feature extraction) ve öğrenme***

- Bu aşamada, ön işleme süreci sonrasında elde edilen ikili görüntü üzerinde nesneler tespit edilir ve her bir nesneye ait özellikler çıkarılır. Bu süreçte, nesnelerin görüntü düzleminde kapladığı alan, boyutları ve merkez koordinatları gibi bilgiler özellik vektörleri içerisinde yer alır (Solak ve Altınışık,2017). CNN katmanları, görüntüdeki önemli özellikleri (kenarlar, dokular, şekiller) çıkarır.
- Derin öğrenme modelleri, bu özellikleri öğrenerek nesneleri veya desenleri sınıflandırır.

#### ***Sınıflandırma ve segmentasyon***

Fiziksel ya da soyut nesnelerin benzer özelliklerine göre gruplandırılması süreci olarak adlandırılan kümeleme literatürde, veri kümeleme veya küme analizi olarak da geçmektedir. Kümeleme analizinde, çok boyutlu ve çok değişkenli verilere sahip nesneler desenler, noktalar veya nesneler kendi doğal benzerliklerine göre anlamlı gruplar halinde sınıflandırılır.

Görüntüler belirli kategorilere ayrılır (örneğin: çiçek, köpek, motosiklet) (Solak ve Altınışık,2017).

Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri aşağıda sıralanmıştır (İnik ve Ülker,2017).

- Convolutional Neural Networks (CNN)
- ResNet, VGG, Inception
- YOLO (You Only Look Once), Faster R-CNN, SSD
- U-Net, Mask R-CNN
- Alex Net
- ZF Net
- GoogLeNet
- Microsoft RestNet

### **Evrişimsel sinir ağları (ESA)**

Evrişimsel Sinir Ağları (CNN- Convolutional Neural Networks), özellikle görüntü işleme ve bilgisayarlı görü alanlarında kullanılan en temel derin öğrenme modelleridir. Geleneksel yapay sinir ağlarından farklı olarak CNN'ler, görüntülerdeki uzamsal ilişkileri koruyarak daha verimli özellik çıkarımı yapar. İnsan beynindeki görsel korteksten esinlenilmiştir. ESA mimarisi, genel hatlarıyla üç ana bölümden oluşur: ilk aşamalar konvolüsyon ve havuzlama katmanlarını içerirken, son aşama tam bağlı katmandan ve ardından gelen sınıflandırma katmanından oluşmaktadır. ESA mimarisi, birbirine ardışık olarak yerleştirilmiş, çok sayıda eğitilebilir bileşen içeren katmanlardan meydana gelir. Bu yapıda, giriş verisi katmanlar boyunca işlemde geçirilir; her katmanda belirli özellikler çıkarılarak temsil derinleştirilir. Eğitim süreci sonunda, modelin ürettiği çıktı ile gerçek değer karşılaştırılır ve aradaki fark (hata) hesaplanır. Bu hata, geriye yayılım algoritması aracılığıyla ağın tüm ağırlıklarına geri iletilir ve böylece her bir iterasyonda ağırlıklar güncellenerek modelin doğruluğu artırılır (İnik ve Ülker,2017).

Evrişimsel Sinir Ağları (ESA) genellikle görüntü sınıflandırma amacıyla kullanılırken, Bölgesel Evrişimsel Sinir Ağları (B-ESA) ise daha çok nesne tespiti görevlerinde tercih edilmektedir.


Literatürde ESA için kendini kanıtlamış mimariler vardır. Bunlardan en çok bilinenleri AlexNet, LeNet-5, VGGNet, GoogLeNet, Microsoft ResNet, DenseNet, EfficientNet, Vision Transformer olarak sıralanabilir.

### **Evrişimsel sinir ağıları (CNN temel bileşenleri)**

- **Giriş Katmanı:** ESA'nının ilk katmanıdır. Veri sisteme ham haliyle giriş yapmaktadır. Burada modelin başarılı olabilmesi için kritik nokta giriş verisinin boyutudur. Bu durum modelin başarı oranını artırma ihtimalini yükseltse de hem test ve eğitim süreleri uzayacak hem de bellek ihtiyacı artacaktır. Tam tersi durumda ağ derinliği azalacağından optimum bir giriş verisi boyutu seçmek çok önemlidir (İnik ve Ülker,2017)
- **Evrişim Katmanı:** Konvolüsyon katmanı sinir ağlarının temelini oluşturduğundan bahsetmiştik. Önceden tanımlanmış bir filtrenin (kernel) tüm girdi görüntüsü üzerinde kaydırılmasıyla, girdinin belirgin özelliklerini ortaya çıkarmayı hedefler. Filtreleme işlemi sonucunda, giriş verisinden boyut olarak daha küçük bir çıktı matrisi elde edilir. (Doğan ve Türkoğlu,2018). Söz konusu filtreler katmanlı mimarinin çok önemli olmazsa olmaz bir unsurudur. Filtreler, çıktı verisini meydana getirmek için bir önceki katmandan gelen görüntülere konvolüsyon işlemini uygularlar. Kenarlar, dokular, şekiller gibi özellikler farklı filtreler ile yakalanır. Her filtre, belirli bir görsel deseni öğrenir. Konvolüsyon işlemi tamamlandığında aktivasyon haritası ortaya çıkar.
- **Aktivasyon Fonksiyonu:** Konvolüsyon katmanından sonra gelen Aktivasyon (ReLU) katmanı, doğrultucu amaçlı her bir ESA nöron çıkışına uygulanır. Negatif değerleri 0 yaparak doğrusal olmayan özellikler kazandırır. Pozitif değerleri ise olduğu gibi geçirerek modelin karmaşık desenleri öğrenmesini kolaylaştırır. Bu katman modelin daha hızlı öğrenmesine katkıda bulunur (Doğan ve Türkoğlu,2018).
- **Havuzlama Katmanı:** Genellikle ReLU katmanından sonra gelen bu katman, Maksimum havuzlama veya ortalama havuzlama kullanılarak verileri özetler, boyutlarını azaltır ve böylece ağı sonraki katmanlarına daha düşük boyutlu bir girişini sağlar. Ağda dolaşan veri boyutunun (Genişlik x Yükseklik) küçülmesi ağı hızının artmasını, hesaplama miktarının süresinin kısılmasını ve ihtiyaç duyulan bellek miktarının düşmesine katkı sağlar (Doğan ve Türkoğlu,2018). Hesaplama maliyetini düşürerek modelin daha hızlı çalışmasına yardımcı olur.
- **Tam Bağlantılı Katman:** Evrişim katmanlarında öğrenilen özellikler, geleneksel yapay sinir ağı ile sınıflandırılır. Tam bağlı katmandaki bir dizi (vektör) şeklinde düzenlenmiş her bir nöron, bir önceki katmandaki tüm aktivasyonlara bağlıdır. Bu katmanın temel özelliği, önceki katmanlardan gelen özellikleri kullanarak


sınıflandırma yapmasıdır. Yani, nesnenin hangi sınıfa ait olduğu, çıkarılan özelliklerin analiz edilmesiyle belirlenir (Doğan ve Türkoğlu,2018).

- **Dropout Katmanı:** ESA’da büyük verilerle işlem yapılması sebebiyle bazı durumlarda çok katmanlı yapay sinir ağlarının eğitimi esnasında, ağı eğitim verisini ezberlemesi anlamına gelen 'aşırı öğrenme' durumu meydana gelebilmektedir. Bu durumun önüne geçmek için kullanılan bu katmanda, ağıdaki bazı nöronların geçici olarak devre dışı bırakıldığı 'dropout' gibi düzenleme yöntemleri kullanılır. Böylece ağ, genelleme yeteneğini artırarak sadece eğitim verisini değil, daha önce görmediği verileri de doğru şekilde tahmin edebilir (Doğan ve Türkoğlu,2018). Şekil 46’da DropOut uygulaması sembolize edilmiştir.



**Şekil 46.** DropOut katmanı uygulaması (İnik ve Ülker,2007)

- **Sınıflandırma Katmanı:** Son katman olarak bilinen ve genellikle tam bağlı katmandan sonra gelen bu katmanda, hedef sınıf sayısı kadar çıktı üretilir ve sınıflandırma işlemi yapılır. Bir başka deyişle sınıflandırma katmanının çıkış değeri, sınıflandırması yapılacak obje ile aynı sayıdadır. Her bir çıktı, belirli bir sınıfa ait olma olasılığını temsil eder ve genellikle softmax aktivasyon fonksiyonu kullanılarak bu olasılık dağılımı elde edilir (Doğan ve Türkoğlu,2018). Şekil 47’de Evrimsel Sinir Ağı (CNN) mimarisinin katmanlara dayalı yapısı detaylı şekilde gösterilmektedir.



**Şekil 47.** CNN mimari yapısı (Şebin,2022)

Bölgesel evrişimsel sinir ağları (B-ESA), özellikle görüntü işleme ve desen tanıma alanında kullanılan derin öğrenme modelleridir. Görüntü verilerini analiz etmek ve özelliklerini çıkarmak için tasarlanmışlardır. ESA'lar ne var sorusunun cevabını ararken B-ESA nerede ne var sorusunu yanıtlamaya çalışır. CNN bir fotoğrafa bakıp "Bu bir kedi." der. R-CNN ise aynı fotoğrafa bakıp "Şu köşede bir kedi var, burada da bir masa var." der ve her nesnenin yerini çizer.

CNN'lerin temel yapı taşı "evrişim" adı verilen matematiksel bir işlemdir. Evrişim işlemi, giriş verisine bir filtre uygulayarak giriş verisindeki lokal özellikleri vurgular. Bu filtreler, görüntülerdeki çizgiler, kenarlar, köşeler gibi özellikleri yakalamak için önceden eğitilen ağırlıklarla temsil edilir.

Bölgesel evrişimsel sinir ağları da evrişim katmanlarından ve ardışık olarak birleştirme (pooling) katmanlarından oluşur. Evrişim katmanları, giriş verisindeki özellikleri çıkarmak için evrişim işlemini uygular. Birleştirme katmanları ise özellik haritalarının boyutunu azaltır ve hesaplama maliyetini azaltırken, özelliklerin genelleştirilmesini sağlar.

Bölgesel evrişimsel sinir ağları, bilgisayarlı görü ve desen tanıma alanında büyük bir ilerleme kaydetmiştir. Özellikle görüntü sınıflandırma, nesne tespiti, yüz tanıma, doğal dil işleme ve tıbbi görüntüleme gibi birçok uygulama alanında çok iyi sonuçlar elde etmişlerdir.

### **Evrişimsel sinir ağları ile görüntü analizi**

Evrişimsel Sinir Ağları (Convolutional Neural Networks- CNN'ler), özellikle görüntü analizi için sıklıkla tercih edilen derin öğrenme modelleri olarak karşımıza çıkmaktadır. Evrişimsel sinir ağları ile görüntü analizini yapmak için izlenebilecek temel adımlar şöyle sıralanabilir:

- 1. Veri toplama, hazırlama ve etiketleme:** Görüntü analizi için ilk adım eğitim veri setlerini toplamaktır. Bu veri setleri, analiz yapmak istenilen nesneleri, etiketleriyle birlikte içermelidir. Örneğin, bir yapıdaki kusur ve çatlakları sınıflandırmak isteniliyorsa, çatlak görüntülerini içeren bir veri seti oluşturulması gerekir. Görüntülerin boyutları ve şekli test ve eğitim sürecinin işleyişi açısından çok önemlidir.
- 2. Veri Ön İşleme:** Toplanmış olan görüntü veri setinin ön işlemeye tabi tutulması gereklidir. Bu adımda kameradan elde edilen görüntü üzerinde sırasıyla filtreleme, gri tonlamaya dönüştürme ve ikili görüntüye çevirme işlemleri uygulanır. Bu işlemler sayesinde, görüntüde yer alan ve analiz edilmek istenen nesneler daha belirgin hale gelir ve işlenmeleri kolaylaşır. Görüntüleri ölçeklendirme,


boyutlandırma veya normalleştirme gibi işlemlerle uygun formata getirilir (Solak ve Altınışik,2017).

3. **Model Oluşturma:** Evrişimsel sinir ağı modelinin oluşturulması gerekmektedir. Evrişimsel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlar gibi bileşenler kullanılarak bir CNN mimarisi tasarlanabilir. Ya da kullanıma hazır mimarilerden faydalanılarak çalışmalar yürütülebilir. Bu katmanlar, görüntüleri işleyerek özellikleri çıkaracak ve sınıflandırma veya nesne tespiti gibi görevleri gerçekleştirecektir.
4. **Model Eğitimi ve Özellik Çıkarımı:** Oluşturulan evrişimsel sinir ağı modelinin eğitilmesi gerekmektedir. Eğitim için oluşturulan görüntü veri seti kullanılarak modeli öğrenmeye başlatılabilir. Ön işleme süreciyle elde edilen ikili görüntü üzerinde nesneler tespit edilir ve her bir nesneye ait özellikler çıkarılır. Nesnelerin görüntü düzleminde kapladığı alan, boyutları ve merkez koordinatları gibi bilgiler özellik vektörleri içerisinde yer alır (Akın ve Şahin,2023). CNN katmanları, görüntüdeki önemli özellikleri (kenarlar, dokular, şekiller) çıkarır.
5. **Sınıflandırma ve Segmentasyon:** İşleme tabi tutulan nesnelerin benzer özelliklerine göre gruplandırılması süreci olarak adlandırılan bu aşama, küme analizi olarak da adlandırılmaktadır. Kümeleme analizinde, çok boyutlu ve çok değişkenli verilere sahip nesneler desenler, noktalar veya nesneler kendi doğal benzerliklerine göre anlamlı gruplar halinde sınıflandırılır. Görüntüler belirli kategorilere ayrılır (örneğin: çiçek, köpek, motosiklet) (Solak ve Altınışik,2017).
6. **Model Değerlendirmesi:** Eğitim süreci tamamlandıktan sonra, modelin performansının değerlendirilmesi gerekmektedir. Bu aşamada, test veri seti kullanılarak modelin doğruluğu, hassasiyeti, özgünlüğü ve diğer performans metrikleri değerlendirilmelidir.
7. **Tahminler ve Sonuçlar:** Eğitilen modeli kullanarak yeni görüntüler üzerinde tahminlerde bulunmak mümkündür. Model, sınıflandırma, nesne tespiti veya diğer görüntü analizi görevlerini gerçekleştirebilir.

Yukarıda bahsedilen adımlar, temel bir evrişimsel sinir ağı tabanlı görüntü analizi iş akışını tanımlamaktadır. Uygulamanın gereksinimlerine ve veri setine bağlı olarak, modeli daha karmaşık hale getirmek, hiperparametre ayarlaması yapmak veya veri artırma tekniklerini kullanmak gibi ilave adımlar da uygulanabilir.

## YOLO algoritması

YOLO (You only look once) algoritması gerçek zamanlı nesne takibi için oldukça yaygın olarak kullanılan bir CNN modelidir.



**Şekil 48.** YOLO algoritması çalışma prensibi (Mesci,2021)

YOLO'nun en çok tercih edilme sebeplerinden birisi doğruluk oranının yüksekliği ve tabi ki hızlı olmasıdır. Bunu sağlayan en önemli özelliği ise görüntünün tamamını tek bir ileri besleme işlemiyle analiz ederek yüksek doğruluk ve hıza ulaşabilmesidir. Şekil 48'de görüleceği üzere YOLO mimarisi görüntüyü sabit ölçülü bir karelaj ile bölümlere ayırır. Herhangi bir karede nesne tespit ederse ilgili hücre sınıf ve konum bilgisi üretir. Bu sayede görüntü üzerinde birden çok obje olduğunda bütün nesnelerin eş zamanlı olarak yüksek hızda tespit edilebilir (Doğan,2025).

## ARAŞTIRMA BULGULARI

Bu bölümde, havaalanı kaplamalı saha yüzeylerinde meydana gelen deformasyonların tespiti amacıyla geliştirilen YOLOv11 tabanlı derin öğrenme modelinin eğitimi, doğrulama ve test aşamalarına ilişkin elde edilen bulgular detaylı olarak sunulmaktadır. Uygulanan veri artırma stratejileri ve oluşturulan etiketli veri seti ile modelin farklı yüzey ve ışık koşullarına karşı gösterdiği genel performans değerlendirilmektedir. Ayrıca, çeşitli metrikler (mAP, IoU, doğruluk vb.) üzerinden model başarımı analiz edilerek, sistemin saha uygulamalarına uygunluğu ortaya konulmaktadır.

Çalışmada kullanılan görüntüler, farklı havaalanlarından toplanan çeşitli pist, apron ve taksiyolu yüzeylerine ait fotoğraflardan oluşmaktadır. Bu görseller üzerinden elde edilen yama ve çatlak örnekleri kullanılarak eğitim veri seti oluşturulmuş, ardından çeşitli görüntü iyileştirme ve çeşitlendirme teknikleri yardımıyla modelin genelleme kapasitesi artırılmıştır. Bu kapsamda, yüzey bozulmalarının başarılı şekilde tespiti ve sınıflandırılması için yürütülen analiz sonuçları bu bölümde grafiksel ve sayısal ifadelerle açıklanmaktadır.

### Görüntü İşlemede Kullanılan Ön İşleme Teknikleri

Derin öğrenmede yüksek doğruluğa ulaşmak için görüntülerin ön işleme tabi tutulması hususundan daha önce bahsedilmişti. İşlenecek verilen standardize edilmesi modelin öğrenme sürecini kolaylaştıracak ve performansı artıracaktır. Çalışmada aşağıda sıralanan işlemler uygulanmıştır:

- Yeniden Boyutlandırma: İşlenecek görüntülerin tamamı aynı çözünürlükte 640x640 piksel giriş boyutuna dönüştürülmüştür. Bu sayede modelin sabit mimaride çalışmasına olanak sağlanmıştır.
- Normalleştirme: piksel değerleri 0-1 aralığına çekilerek öğrenme sürecinin hızlanması sağlanmıştır.
- Gürültü Giderme (Noise Reduction veya Denoising): Dijital sinyal işleme, görüntü işleme ve derin öğrenme gibi birçok alanda, veriden istenmeyen bozulmaların (gürültülerin) temizlenmesi işlemidir. Görüntü kalitesini artırmak için uygulanır. Çalışmada gürültülerin etkisini minimize etmek maksadıyla bazı filtreleme teknikleri uygulanmıştır.

- Veri Artırımı: Albumentations kütüphanesi kullanılarak veri artırma yoluna gidilmiştir. Farklı kombinasyonlar crack ve patch sınıfları için seçilmiştir.
- Doldurma: Görsellerin giriş boyutu olan 640x640 boyutuna ulaşması için kenarlara siyah çerçeve ilave edilmiştir.

Kullanılan ön işleme teknikleri ve prosedürü sayesinde hem yapay olarak çeşitlendirilmiş veri üretimi gerçekleştirilmiş hem de sınıflar arası dengesizlik giderilmiştir. Elde edilen görüntüler VOC formatında etiketlenmiş ve bu etiketler otomatik olarak YOLO formatına dönüştürülmüş, dönüşüm sonrası etiketlerin doğruluğu titizlikle denetlenmiştir. Ayrıca, veri artırma sürecinde aynı orijinal görüntüden türetilmiş örneklerin aynı alt kümeye düşmemesine özen gösterilmiş, bu sayede eğitim, doğrulama ve test kümeleri arasında daha dengeli bir dağılım elde edilmiştir.

Şekil 49'da, veri artırımı yöntemi kullanılarak orijinal görüntülerden türetilen yeni görseller sunulmakta olup, bu işlem sayesinde modelin farklı görsel koşullara karşı genelleme yeteneğinin artırılması hedeflenmiştir.



**Şekil 49.** Veri artırımı metoduyla üretilen görseller

Gerçekleştirilen veri artırımı işlemi sonrasında modelin eğitilmesi ve test işlemleri için 2.099 yama görüntüsü ile 6.780 adet çatlak görüntüsü elde edilmiştir. Bu sayede kamera açısı, model, ışık koşullarının farklılığı vb gibi olumsuzlukların negatif etkilerine rağmen tespitlerin başarı oranı artırılabilir.

### Model Eğitimi

Modelin eğitimi aşamasında yama, çatlak vb yüzey deformasyonlarını kapsayan etiketlenmiş görüntülerden meydana gelen bir veri seti kullanılmıştır.

Çeşitli hava alanlarından elde edilen veri seti üzerinde çeşitli veri artırma teknikleri uygulamak suretiyle hem sınıf dengesinin korunması hem de örnek çeşitliliğinin artırılması sağlanmıştır. Parlaklık, döndürme, yansıma ve ayarı gibi işlemler sayesinde, modelin farklı görüntüleme koşullarında genellenmesi sağlanmıştır.

Model eğitimi, Google Colab ortamında, Ultralytics YOLOv11 Medium mimarisi kullanılarak gerçekleştirilmiştir. Eğitim sürecinde, 640x640 çözünürlükte giriş görüntüleri, deneysel olarak belirlenmiş optimum hiperparametreler ve erken durdurma (early stopping) stratejisi kullanılmıştır. Eğitimin her aşamasında, modelin performansı mAP (mean Average Precision), IoU (Intersection over Union) ve doğruluk (accuracy) gibi metrikler üzerinden izlenmiştir.

### **Veri Seti**

Çalışmanın analiz bölümü için çeşitli havaalanlarından 1.000 adet pist/apron/taksiyolu yüzeyi görüntüsü alınmıştır. Bu görüntüler iphone 11 model telefon ile yatay olarak çekilmiştir. Fotoğraflardaki yabancı görüntüler temizlenmek üzere kırılmış, fotoğraf boyutunu küçültmek adına gereksiz alanlar kırılmıştır. Bunun yanı sıra fotoğrafların en / boy eşit olacak şekilde aynı ölçüde olması sağlanmıştır. Farklı havaalanlarından ve kaplamalı saha yüzey koşullarından elde edilen veri setinde farklı ışık koşulları, zemin yüzey dokuları ve hasar tiplerini barındıran geniş bir yelpazeye sahip olunmuştur.

Fotoğraflar çekilirken çeşitli çatlak tipleri, onarım görmüş alanlar, pist işaretlemesi ve aydınlatması elemanları, sağlam yüzeyler ya da deformasyona uğramış sahalar olacak şekilde veri seti oluşması sağlanmıştır. Bu husus modelin çeşitli yüzey koşullarına karşı genelleme yeteneğini artırması açısından önemli bir detay olduğu değerlendirilmiştir.

Görseller YOLO algoritması gereklilikleri doğrultusunda LabelMe kullanılarak manuel olarak etiketlenmiştir. Her görsel için sınırlayıcı kutular içerecek şekilde işlem gerçekleştirilmiştir. Şekil 50'de farklı havaalanlarına ait hasarlı yüzey görüntülerinden oluşturulan veri seti örnekleri sunulmakta olup, bu görseller modelin çeşitli saha koşullarında eğitimine olanak sağlamıştır.



Şekil 50. Hasarlı yüzeye ait veri seti örnekleri

Şekil 49’da çeşitli havaalanlarından elde edilen çatlak içeren görsellere dair örnekler sunulmuştur. Rijit kaplamalı sahalarda karşılaşılması muhtemel timsah sırtı hasarı, boyuna çatlak vb hasarlar gösterilmiştir.

Şekil 51’de, çeşitli havaalanlarından elde edilen sağlam yüzeylere ait veri setinden seçilmiş örnekler gösterilmekte olup, bu sayede modelin deformasyon ve hasar tespiti konusunda doğruluğu artırılmıştır.



**Şekil 51.** Sağlam yüzeye ait veri seti örnekleri

Çalışmada oluşturulan veri setinin %80’i eğitim için, %10’u doğrulama için, kalan %10’u ise test için ayrılmıştır. Uygulanan veri oranlaması sayesinde modelin yalnızca öğrenme performansı değil, aynı zamanda görmediği veriler üzerindeki genelleme yeteneği de değerlendirilmiştir. Eğitim seti modelin öğrenmesini sağlarken, doğrulama seti eğitim sırasında hiperparametre ayarlarının izlenmesine yardımcı olmuş, test seti ise nihai başarının bağımsız olarak değerlendirilmesini sağlamıştır.

- Eğitim seti (training set), modelin temel öğrenme sürecini gerçekleştirmesi için kullanılmıştır.

- Doğrulama seti (validation set), eğitim sırasında hiperparametre ayarlarının izlenmesi, modelin aşırı öğrenme eğiliminin gözlemlenmesi ve erken durdurma kriterlerinin belirlenmesi amacıyla kullanılmıştır.
- Test seti (test set) ise modelin eğitimi ve doğrulaması tamamlandıktan sonra, bağımsız ve daha önce hiç görülmemiş veriler üzerinde genel başarımını objektif olarak ölçmek için kullanılmıştır.

Veri setine uygulanan ön işleme adımları ve çeşitli veri artırma teknikleri sayesinde hem sınıf dengesizliği giderilmiş hem de örnek çeşitliliğinin artması sağlanmıştır. Bu işlemler kapsamında; görüntülerin döndürülmesi, yansıtılması, parlaklık ve kontrast ayarlarının değiştirilmesi gibi yöntemler kullanılmıştır.

Uygulanan bu stratejiler, modelin yalnızca eğitim verisi üzerinde değil, aynı zamanda gerçek saha koşullarında karşılaşılabileceği farklı senaryolarda da yüksek performans sergilemesini sağlamayı amaçlamıştır. Böylece model, değişken çevresel koşullara ve farklı görüntüleme durumlarına karşı daha dayanıklı ve genellenebilir bir yapıya kavuşturulmuştur.

## **Etiketleme**


Çalışmada kullanılan bütün görüntüler, YOLO algoritmasının gereklilikleri doğrultusunda etiketlenmiştir. Etiketleme fazında, yüzey hasarları iki temel sınıf altında tanımlanmıştır: çatlak ve yama. Her nesne, ait olduğu sınıf etiketiyle birlikte, sınırlayıcı kutular aracılığıyla konumlandırılmıştır.

Bu kutular; nesnenin x ve y koordinatları, genişlik ve yükseklik değerlerini içermekte olup, tüm bilgiler YOLO formatına uygun şekilde normalize edilmiştir. Etiketleme işlemi, açık kaynaklı LabelMe aracı kullanılarak manuel olarak gerçekleştirilmiştir.

Etiketleme sürecinde özellikle dikkat edilen başlıca hususlar şunlardır:

- Çok küçük çatlakların atlanmaması,
- Benzer hasar türleri arasında sınıf karışıklığının önüne geçilmesi,
- Görüntülerde tutarlı ve sistematik bir etiketleme standardının sağlanması.

Şekil 52, veri etiketleme işleminin LabelMe yazılımı kullanılarak gerçekleştirildiğini ve görüntüler üzerindeki nesnelerin bu araç ile doğru şekilde işaretlendiğini göstermektedir.



Şekil 52. Veri etiketleme işlemi

### Eğitim parametreleri

Modelin eğitimi için programlama dili olarak Python ve PyTorch kütüphanesi tercih edilmiştir. Model eğitimi, GPU destekli bir çalışma ortamı olan Google Colab Pro platformu üzerinde gerçekleştirilmiştir. Bu sayede, eğitim süreci hem daha yüksek hızda tamamlanabilmiş hem de yüksek boyutlu veri setleriyle etkin şekilde çalışılabilmesi mümkün olmuştur.

Eğitim süresi, kullanılan veri setinin büyüklüğü, tercih edilen model mimarisi (YOLOv11 Medium) ve belirlenen hiperparametre ayarları gibi etkenlere bağlı olarak değişiklik göstermiştir. Bu bağlamda, ortalama eğitim süresi 3 ila 4 saat arasında tamamlanmıştır.

Eğitim sırasında aşağıdaki hiperparametreler kullanılmıştır;

- Batch size: 16
- Epoch sayısı: 300 (erken durdurma stratejisi etkinleştirilmiş ve en yüksek doğruluğa 40 epoch mertebesinde ulaşılmıştır)
- Öğrenme oranı: 0.001
- Kayıp fonksiyonu (Loss Function): CrossEntropyLoss

Model eğitim değerleri Şekil 53'te sunulmuştur.

Bu tablo, YOLOv11 modelinin eğitim sürecindeki kayıp değerlerinin düşüşünü göstermektedir. Bir anlamda sahadan sağlamış olduğumuz veri seti ile fine-tuning yapılmış/alana uyarlanmış YOLO modelinin öğrenme süreci boyunca yaptığı hataların nasıl azaldığını ortaya koymaktadır. "Loss" değerleri (kayıp fonksiyonu), modelin yaptığı

tahminlerin ne kadar hatalı olduğunu ölçer. Burada kutu konumu (box loss), sınıf tahmini (cls loss) ve dağılım (dfl loss) gibi farklı hata türlerinin zamanla azaldığı görülmektedir. Kutu konumlandırma, sınıflandırma ve dağılım gibi kayıpların azalması, modelin öğrenme sürecinin istikrarlı ve verimli geçtiğini ortaya koymaktadır. Özellikle overfitting eğiliminin gözlenmemesi, erken durdurma stratejisinin etkili biçimde çalıştığını göstermektedir.

Bu da modelin yüzeydeki bozulmaları (örneğin çatlak veya yama) daha doğru tanımayla başladığını ve öğrenmenin verimli şekilde gerçekleştiğini gösterir. Ayrıca, gereksiz yere ezberleme (overfitting) problemi gözlenmemiştir.

|        |         |          |           |          |           |                                                     |
|--------|---------|----------|-----------|----------|-----------|-----------------------------------------------------|
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 34/300 | 14.5G   | 0.9164   | 0.8871    | 1.204    | 59        | 640: 100% 222/222 [03:58<00:00, 1.07s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.13it/s] |
|        | all     | 816      | 840       | 0.782    | 0.641     | 0.69 0.484                                          |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 35/300 | 14.5G   | 0.9063   | 0.8682    | 1.202    | 46        | 640: 100% 222/222 [03:58<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.14it/s] |
|        | all     | 816      | 840       | 0.774    | 0.637     | 0.714 0.468                                         |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 36/300 | 14.5G   | 0.8944   | 0.8576    | 1.195    | 55        | 640: 100% 222/222 [03:59<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.14it/s] |
|        | all     | 816      | 840       | 0.808    | 0.623     | 0.703 0.502                                         |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 37/300 | 14.5G   | 0.8923   | 0.8528    | 1.194    | 53        | 640: 100% 222/222 [03:59<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.14it/s] |
|        | all     | 816      | 840       | 0.751    | 0.641     | 0.724 0.498                                         |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 38/300 | 14.4G   | 0.8896   | 0.8402    | 1.189    | 55        | 640: 100% 222/222 [03:59<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.13it/s] |
|        | all     | 816      | 840       | 0.763    | 0.667     | 0.742 0.519                                         |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 39/300 | 14.5G   | 0.878    | 0.8383    | 1.183    | 60        | 640: 100% 222/222 [03:59<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.14it/s] |
|        | all     | 816      | 840       | 0.883    | 0.627     | 0.75 0.492                                          |
| Epoch  | GPU_mem | box_loss | cls_loss  | dfl_loss | Instances | Size                                                |
| 40/300 | 14.5G   | 0.874    | 0.813     | 1.18     | 35        | 640: 100% 222/222 [03:59<00:00, 1.08s/it]           |
|        | Class   | Images   | Instances | Box(P    | R         | mAP50 mAP50-95): 100% 13/13 [00:11<00:00, 1.14it/s] |
|        | all     | 816      | 840       | 0.896    | 0.623     | 0.77 0.523                                          |

Şekil 53. Model eğitim değerleri

YOLO mimarisine özgü olarak kullanılan Non-Maximum Suppression (NMS) algoritması, eğitim ve çıkarım sürecinde optimize edilmiştir. Bu optimizasyon sayesinde, aynı nesneye ait birden fazla sınırlayıcı kutu (bounding box) yerine, yalnızca en yüksek güven skoruna sahip kutunun gösterilmesi sağlanmıştır.

NMS parametrelerinin hassas şekilde ayarlanması, özellikle çatlak ve yama gibi birbirine yakın konumda ve benzer görsel özelliklere sahip sınıfların yer aldığı görüntülerde modelin kararlılığını ve doğruluk oranını artırmıştır. Bu sayede, yanlış pozitif tespitler azaltılmış ve modelin nesne ayrıştırma performansı güçlendirilmiştir.

## Eğitim Sonuçları ve Değerlendirme

Eğitim süreci sonunda modelin performansı, çok yönlü değerlendirme sağlayan çeşitli metrikler kullanılarak analiz edilmiştir. Bu kapsamda model başarımı şu ölçütlerle değerlendirilmiştir:

- Doğruluk (Accuracy)
- Ortalama Hassasiyet (Precision)
- Geri Çağırma (Recall)
- F1 Skoru
- mAP (mean Average Precision)

Bu metrikler, modelin hem sınıf içi tutarlılığı hem de genel tespit başarımı hakkında kapsamlı bilgi sunmuştur. Ayrıca eğitim süresince kaydedilen kayıp grafikleri, modelin öğrenme dinamiklerini incelemek amacıyla değerlendirilmiştir. Bu grafikler, özellikle aşırı öğrenme ve yetersiz öğrenme gibi olası problemleri tespit etmek ve gerektiğinde müdahale etmek için kritik bir rol oynamıştır

Şekil 54 model eğitimi sürecinde elde edilen doğruluk, kayıp ve performans metrikleri gibi modelin öğrenme sürecini daha detaylı gösteren eğitim grafiklerini içermektedir.

- Precision (Kesinlik): Modelin tespit ettiği bozulmaların ne kadarının gerçekten doğru olduğunu ölçer.
- Recall (Duyarlılık): Gerçekten var olan bozulmaların ne kadarını modelin doğru tespit ettiğini gösterir.
- mAP (mean Average Precision): Genel başarı oranını temsil eden kapsamlı bir ölçüdür.


Grafiklerde bu metriklerin zamanla yükselmesi, modelin hem doğruluk hem de genelleme açısından başarılı olduğunu göstermektedir. Eğitim ve doğrulama kayıplarının düşmesi de modelin farklı yüzey koşullarına uyum sağlayabildiğini ifade eder.

Şekil 54 incelendiğinde, train/box\_loss, train/cls\_loss ve train/df\_l\_loss grafiklerinde, eğitim sırasında kutu konumu (box), sınıflandırma (cls) ve dağılım (df\_l) kayıplarının azaldığı görülmektedir. Bu durum, modelin öğrenme sürecinin başarılı şekilde ilerlediğini ifade eder. Val/box\_loss, val/cls\_loss ve val/df\_l\_loss grafiklerinde ise doğrulama setinde aynı kayıp değerlerinin genel olarak azaldığı, ancak biraz dalgalanma olduğu gözlemlenmektedir. Bu, modelin genelleme yeteneğini göstermektedir. Metrics/precision, metrics/recall, metrics/mAP\_50 ve metrics/mAP\_50-95 grafiklerinde ise eğitim boyunca kesinlik (precision) ve duyarlılık (recall) gibi başarı metriklerinde artış trendi gözlenmektedir. Precision ve recall yaklaşık 0,7 seviyelerine ulaşmıştır. Bu, modelin tespit ve sınıflandırma görevlerinde iyi performans verdiğini göstermektedir.

Modelin eğitim performansını yansıtan bu grafik seti, doğruluk (accuracy), precision, recall, mAP gibi metriklerin zamanla nasıl geliştiğini sunmaktadır. Grafiklerde gözlenen artış

trendi, modelin hem sınıflandırma hem de konumlandırma açısından sağlam bir öğrenme gerçekleştirdiğini ortaya koyar. Eğitim ve doğrulama kayıplarındaki genel düşüş, genelleme yeteneğinin başarılı biçimde kazanıldığını desteklemektedir.

300 epoch değeri ile çalıştırılan eğitim prosedürü sonucunda, yaklaşık 40 epoch'tan sonra model performansının düştüğü, loss (hata) değerlerinin yükselmeye başladığı gözlemlenmiştir. Bu durum Şekil 53'te sunulan performans metriklerinin epoch sayısına göre değişim eğilimleri üzerinde açıkça gözlemlenmektedir.



**Şekil 54.** Eğitim grafikleri

Modelin test verisi üzerindeki genel performansı, çeşitli metrikler üzerinden değerlendirilmiştir. Elde edilen sonuçlara göre:

- Genel doğruluk oranı: **%91,2**
- Ortalama IoU (Intersection over Union): **0,73**

Bu değerler, eğitilen modelin pist ve taksiyolu yüzeylerindeki yapısal bozuklukları yüksek doğrulukla tanımlayabildiğini ve nesne sınırlarını konumlandırmada güçlü bir performans sergilediğini göstermektedir.

Sınıf bazında yapılan detaylı başarı analizi Tablo 5'te gösterilmiştir. Crack (Çatlak) sınıfı için precision %89,6 ve recall %90,1 olarak yüksek bir performans sergilemiştir. Bu,

modelin çatlakları doğru şekilde tanımlamada (kesinlik) ve mevcut çatlakların çoğunu tespit etmede (duyarlılık) oldukça başarılı olduğunu gösterir. Patch (Yama) sınıfında ise precision %90,1 ile oldukça yüksek olup, model yama sınıfına ait örnekleri doğru tanımlamada başarılıdır. Ancak recall %84,8 seviyesinde olup, yamaların bir kısmını tespit etmede çatlakla kıyasla biraz daha düşük kalmıştır.


**Tablo 5.** Başarı Oranları

| Sınıf | Precision (%) | Recall (%)  |
|-------|---------------|-------------|
| Crack | <b>89,6</b>   | <b>90,1</b> |
| Patch | <b>90,1</b>   | <b>84,8</b> |


Bu bulgular, modelin hem küçük ölçekli hem de karmaşık yapıya sahip yüzey bozulmalarını ayırt etmede başarılı olduğunu ortaya koymaktadır. Özellikle 'crack' sınıfında yüksek recall değeri, modelin çatlakları atlamadan tespit etme becerisini gösterirken; 'patch' sınıfındaki yüksek precision, modelin yama gibi bozulmaları daha az yanlış pozitifle sınıflandırdığını göstermektedir.

Şekil 55'te, Precision-Recall (Kesinlik-Duyarlılık) eğrileri sunulmaktadır. Bu grafik, modelin farklı eşik değerlerinde ne kadar doğru (precision) ve ne kadar kapsamlı (recall) olduğunu gösterir. Bir başka ifade ile modelin doğru tespit oranı (precision) ile kapsam oranı (recall) arasındaki ilişkiyi ortaya koyar. Crack (çatlak) sınıfına ait eğri açık mavi renkte olup, model bu sınıf için genel olarak daha düşük bir precision-recall performansına sahiptir. Crack (çatlak) sınıfında model çoğu çatlak bulabiliyor (yüksek recall), ancak bazılarını yanlışlıkla başka bir bozulma gibi algılayabiliyor. Grafik üzerindeki değer, bu sınıf için 0.693 mAP@0.5 olarak verilmiştir. Eğri, recall arttıkça precision'un düştüğünü göstermektedir ki bu tipik bir durumdur. Patch (yama) sınıfı turuncu eğri ile gösterilmiştir ve bu sınıf için model daha yüksek bir precision-recall performansı sunmaktadır (mAP@0.5 = 0.848). Bu sınıfta daha doğru tanımlar yapılmış (yüksek precision) olup, mAP@0.5 değeri, bu iki metriğin dengelendiği genel başarı ölçüsüdür. 0.771 gibi bir ortalama, uygulamada tatmin edici bir performans anlamına gelir. Sonuç olarak ortaya çıkan bu veriler modelin yamaları tespit etme ve doğru sınıflandırmada daha başarılı olduğunu göstermiştir. Kalın mavi çizgi, tüm sınıfların ortalaması olan mAP@0.5 = 0.771 değerini ifade etmektedir. Bu da modelin genel olarak iyi bir performans sergilediğini ifade eder.

Özetle, model yamalar üzerinde çatlaklara kıyasla daha başarılı sonuçlar verirken, genel olarak da tatminkar bir doğruluk ve kapsama oranı yakalamıştır. Precision ile recall arasında doğal bir denge olduğu ve yüksek recall değerlerinde precision'un düştüğü gözlemlenmektedir.




Şekil 55. Precision-recall eğrileri




Şekil 56. Recall-confidence eğrileri

Şekil 56’da sunulan Recall-Confidence grafiği modelin farklı güven skoru eşiklerinde (confidence threshold) ne ölçüde kapsamlı tespit (recall) yaptığını gösterir. Bir başka deyişle bu grafik, modelin hangi güven seviyesi eşiklerinde daha çok bozulma tespiti yaptığını gösterir. Confidence, modelin kendi tahminine ne kadar güvendiğini ifade eder. Düşük eşiklerde daha fazla bozulma tespit edilir (yüksek recall), ancak hatalı tespit sayısı da artabilir. Özetle Recall-Confidence grafiği saha uygulamalarında uygun güven eşiği belirlemek için kullanılır. Eşik değeri yükseldikçe recall’un azalması beklenen bir davranıştır ve modelin güven skoru ayarlamalarına karşı duyarlılığını ortaya koyar. Uygun eşik değeri belirlenerek kaçırılan hasarların minimuma indirilmesi mümkündür.



Şekil 57. Precision-confidence eğrileri

Şekil 57’de sunulan Modele ait Precision-Confidence eğrileri modelin güven skoru arttıkça ne ölçüde doğru tahmin yaptığı göstermektedir. Yani, model çok emin olduğunda genellikle doğru tahmin yapmaktadır. Bu da kritik bölgelerde (pist veya taksiyolu) gereksiz alarm sayısını azaltmak açısından önemlidir. Yüksek eşik değerlerinde precision’un arttığı görülmektedir ki bu durum, modelin yüksek güven skorlarında daha az yanlış pozitif verdiğini ve özellikle yama tespitinde daha doğru kararlar aldığını göstermektedir.



Şekil 58. F1-confidence eğrileri

Precision ve recall’un dengelendiği F1 skoru üzerinden, modelin optimum karar eşiklerini belirlemek için kullanılır. F1 skoru, precision ile recall arasında bir denge sağlar. Bu grafik, hangi güven seviyesi değerinin bu dengeyi en iyi kurduğunu gösterir. F1 skoru yüksek


olduğunda hem doğru tespit oranı yüksektir hem de kaçırılan bozulma sayısı düşüktür. Bu, saha uygulamasında kullanılacak eşik değerini belirlemek için teknik bir referans sunar.

Şekil 58’de sunulan grafik, hangi confidence düzeyinde F1 skorunun maksimum olduğunu göstererek saha uygulamaları için optimum eşik ayarı konusunda referans sunar. Model, genellikle 0.5 civarındaki eşik değerlerinde en dengeli sonuçları vermiştir.


### Genelleme yeteneği ve mAP analizi

Modelin eğitim ve doğrulama setleri üzerindeki mAP@0.5 değeri %91,2, test seti üzerinde %77,1 olarak elde edilmiştir. Bu iki değer arasındaki fark, makul seviyede olup modelin daha önce görmediği verilere karşı genelleme kapasitesini koruduğunu göstermektedir.

Ayrıca, test setinde elde edilen mAP oranının kabul edilebilir düzeyde yüksek olması, modelin aşırı öğrenme göstermediğini ve eğitim sırasında öğrenilen özelliklerin yeni veri üzerinde de başarılı şekilde uygulanabildiğini ortaya koymaktadır. Bu durum, uygulanan veri artırma stratejileri, hiperparametre ayarlamaları ve erken durdurma mekanizmasının etkinliğini desteklemektedir.



Şekil 59. Test verisi üzerindeki tespitler



**Şekil 59.** Test verisi üzerindeki tespitler (devamı)

Gerçek saha koşullarında modelin test verileri üzerindeki performansını gösteren bu Şekil 59’da sunulan görsel çıktılar, eğitim sırasında öğrenilen özelliklerin yeni ve daha önce görülmemiş yüzeylerde de başarılı biçimde uygulanabildiğini ortaya koymaktadır. Tespit edilen çatlak ve yamaların konumlarının doğruluğu, modelin saha uygulamaları için pratik bir araç olabileceğini destekler niteliktedir.

Modelin daha önce hiç görmediği (test seti) görüntülerde ne kadar başarılı olduğunu gösteren çıktılarda çatlaklar ve yamalar başarıyla sınıflandırılmış ve konumlandırılmıştır. Bu, modelin yalnızca eğitim verilerinde değil, gerçek saha koşullarında da yüksek performans gösterdiğini kanıtlar. Ayrıca test setindeki başarı oranının eğitim setine yakın olması, modelin ezberlemeye dayalı değil, genelleyci bir şekilde çalıştığını göstermektedir.

### **YOLOv11 algoritmasının diğer modellerle karşılaştırılması**

Veri seti üzerinde YOLO v11 haricinde aşağıdaki modeller ile eğitim gerçekleştirilmiş ve Tablo 6’daki sonuçlar alınmıştır.

**Tablo 6.** Modellerin Başarı Oranları

| Model                  | Precision (%) | Recall (%)   | F1-Score (%) | Epoch (Max perf.) | mAP@0.5 (%) | mAP@0.5:0.95 (%) | Eğitim Süresi (saat) |
|------------------------|---------------|--------------|--------------|-------------------|-------------|------------------|----------------------|
| <b>YOLOv11</b>         | <b>89.85</b>  | <b>87.45</b> | <b>88.63</b> | <b>41</b>         | <b>91.2</b> | <b>77.1</b>      | <b>3.5</b>           |
| <b>ResNet-50</b>       | 84.2          | 82.1         | 83.14        | 48                | 86.3        | 71.8             | 6.2                  |
| <b>VGG-16</b>          | 79.8          | 78.6         | 79.19        | 57                | 81.4        | 65.2             | 8.1                  |
| <b>EfficientNet-B3</b> | 86.1          | 84.3         | 85.19        | 28                | 88.7        | 74.5             | 5.8                  |
| <b>Faster R-CNN</b>    | 82.7          | 80.9         | 81.79        | 33                | 84.6        | 69.3             | 9.4                  |


Modellerin sınıf bazlı performans analizi karşılaştırıldığında Tablo 7’deki sonuçlar elde edilmiştir.

**Tablo 7.** Modellerin Performans Tablosu

| Model                  | Çatlak (Crack) |             | Yama (Patch)  |             |
|------------------------|----------------|-------------|---------------|-------------|
|                        | Precision (%)  | Recall (%)  | Precision (%) | Recall (%)  |
| <b>YOLOv11</b>         | <b>89.6</b>    | <b>90.1</b> | <b>90.1</b>   | <b>84.8</b> |
| <b>ResNet-50</b>       | 83.8           | 85.2        | 84.6          | 79.0        |
| <b>VGG-16</b>          | 78.2           | 81.4        | 81.4          | 75.8        |
| <b>EfficientNet-B3</b> | 85.7           | 86.8        | 86.5          | 81.8        |
| <b>Faster R-CNN</b>    | 81.9           | 83.6        | 83.5          | 78.2        |

Çalışmada karşılaştırılan tüm modeller içerisinde YOLOv11 en yüksek performansı sergilemiştir. Model, mAP@0.5 değerinde %91,2 ve mAP@0.5:0.95 değerinde %77,1 ile doğruluk açısından rakiplerinden açık şekilde üstün gelmiştir. Ayrıca yalnızca 3,5 saatlik eğitim süresi ile hem eğitim hem de gerçek zamanlı kullanımda büyük avantaj sağlamaktadır. Sınıf bazlı analizde, çatlak tespitinde ulaşılan %90,1 recall değeri kritik hasarların gözden kaçırılma riskini en aza indirmiştir. Yama tespitinde ise %90,1 precision oranı ile yanlış alarm oranı minimum seviyede kalmıştır. Diğer modeller incelendiğinde; ResNet-50 dengeli bir performans sunmasına rağmen hız açısından orta düzeyde kalmıştır. VGG-16, test edilen modeller arasında en düşük doğruluk ve en yavaş çıkarım süresiyle dikkat çekmiştir. EfficientNet-B3, görece düşük parametre sayısına rağmen iyi bir doğruluk elde ederek verimlilik açısından öne çıkmıştır. Faster R-CNN ise literatürde güçlü bir model olarak kabul edilmesine karşın, çıkarım hızının düşük olması nedeniyle pratik uygulamalarda sınırlı kalmıştır. Tüm bu değerlendirmeler ışığında, YOLOv11 havaalanı zemin defekti tespitinde doğruluk ve hız parametreleri bakımından en uygun model olarak öne çıkmakta ve hem gerçek zamanlı hem de güvenilir analiz gerektiren senaryolar için en uygun tercih olmaktadır.

Tablolarda belirtilen performans metrikleri, ilgili modellerin çalıştırılması esnasında early\_stop özelliği kullanılarak elde edilmiş olup her model için en iyi performansı ifade etmektedir. Maksimum 60 epoch çalışacak şekilde başlatılan eğitim prosedürleri her model için en iyi değere ulaştıktan sonra düşüşe geçtiğinde otomatik olarak sonlandırılmış, ilgili epoch değerine tabloda yer verilmiştir. Modellerin eğitim grafikleri Şekil 60'ta sunulmuştur.



**Şekil 60.** Karşılaştırılan modellerin eğitim grafikleri

## SONUÇLAR VE ÖNERİLER

Havaalanlarında pist, apron ve taksi yollarının mevcut durumlarının düzenli olarak izlenmesi ve bu sahalarda oluşabilecek hasarların hızlıca tespit edilerek müdahale edilmesi, uçuş güvenliği açısından kritik öneme sahiptir. Ancak mevcut uygulamalarda bu süreçler çoğunlukla manuel yöntemlerle yürütülmekte, bu da insan hatasına açık, zaman alıcı ve yüksek iş gücü gerektiren bir denetim mekanizmasına neden olmaktadır. Özellikle çatlak gibi yüzey kusurlarının tespiti, uzmanlık gerektiren ve doğruluğu değerlendiren kişinin bilgi birikimine bağlı olan öznel bir süreçtir. Bu durum, saha güvenliğinin sürekli ve nesnel şekilde sağlanmasını zorlaştırmakta; bakım-onarım süreçlerinde aksamalara ve maliyet artışlarına yol açabilmektedir.

Günümüzde yapay zeka ve derin öğrenme teknolojilerindeki hızlı gelişmeler, bu tür manuel süreçlerin otomatik sistemlerle desteklenmesini mümkün hale getirmiştir. Bu çalışmada, uçak pistleri ve benzeri altyapı yüzeylerinde meydana gelen bozulmaların (çatlak ve yama gibi) tespiti amacıyla geliştirilen YOLOv11 tabanlı derin öğrenme modeli, eğitim, doğrulama ve test aşamalarında kapsamlı bir şekilde değerlendirilmiştir. Türkiye'deki çeşitli havaalanlarından elde edilen 1000 adet görüntüden (650 hasarsız, 350 hasarlı) oluşan özel bir veri seti oluşturulmuş ve model bu verilerle eğitilmiştir. Elde edilen sonuçlar, sınırlı ancak çeşitli yapıya sahip veri setiyle eğitilen YOLOv11 modelinin yüksek doğrulukla tespit gerçekleştirebildiğini göstermiştir. Performans ölçütleri olan mAP, IoU, precision ve recall sonuçları, modelin yalnızca teorik değil, aynı zamanda pratik uygulamalarda da güvenilir bir başarı sergilediğini ortaya koymaktadır.

Görsel çıktı analizleri ile desteklenen model sonuçları, çatlak ve yüzey deformasyonlarının türlerini ayırt etmede ve konumlarını belirlemede etkin bir doğruluk sağlamıştır. Elde edilen grafikler analiz edildiğinde ve sonuçların bütününe bakıldığında, geliştirilen yapay zeka tabanlı modelin doğruluk, genelleme ve saha uygulanabilirliği açısından başarılı bir performans sergilediği söylenebilir. Elde edilen veriler değerlendirildiğinde;

- Eğitim Süreci Kararlılığı: Modelin eğitim süreci boyunca kayıp fonksiyonlarında düzenli ve istikrarlı bir düşüş gözlenmiştir. Bu durum, modelin öğrenme sürecinde dengeli bir şekilde ilerlediğini ve ezberleme gibi istenmeyen durumlara düşmeden genelleme yeteneği kazandığını göstermektedir. Modelin eğitim sırasında kayıpları düzenli bir biçimde azalmış ve metriklerde (doğruluk, kesinlik, duyarlılık gibi)

iyileşme sağlanmıştır. Bu durum, modelin yeterince verimli öğrenme gerçekleştirdiğini ve eğitimin başarıyla tamamlandığını göstermektedir. Ayrıca eğitim doğruluğu ve doğrulama verisi üzerindeki başarı oranlarının birbirine yakın seyretmesi, modelin farklı yüzey tiplerine uyum sağlayabildiğini işaret etmektedir.

- Sınıflandırma ve Konumlama Başarımı: Precision-recall eğrileri, modelin sınıflandırma performansını detaylı biçimde ortaya koymaktadır. Çatlak sınıfı için  $mAP@0.5$  değeri 0.693, yama sınıfı için ise 0.848 olarak hesaplanmıştır. Bu farklılık, modelin yama gibi daha belirgin yüzey bozulmalarını daha yüksek doğrulukla tespit edebildiğini; ancak çatlak gibi daha ince ve belirsiz bozulmalarda kısmen daha düşük başarı gösterdiğini göstermektedir. Genel  $mAP$  ortalamasının 0.771 seviyesinde olması, modelin çok sınıflı bozulma tespitinde genel anlamda yüksek başarı sağladığını ortaya koymaktadır.
- Bozulma Tespit Performansı: Precision-recall, F1 ve  $mAP$  gibi değerlendirme metrikleri, modelin yüzey bozulmalarını (çatlak ve yama gibi) yüksek doğruluk oranıyla tespit ettiğini ortaya koymaktadır. Özellikle  $mAP@0.5$  değerinin 0.77 gibi yüksek bir seviyede olması, sınırlı ve çeşitli veriyle eğitilmiş olmasına rağmen modelin güçlü bir genelleme yeteneği kazandığını göstermektedir.
- Eşik Değeri Analizi (Confidence Threshold): Confidence tabanlı recall, precision ve F1 skorlarına ilişkin grafikler modelin farklı güven düzeylerinde nasıl davrandığını ve karar verme hassasiyetini analiz etme olanağı sunmuştur. Eşik değeri yükseldikçe precision artmakta, ancak recall azalmaktadır. Bu doğal denge, uygulama amacına göre eşik ayarının optimize edilmesini gerekli kılmaktadır. Özellikle F1 skoru üzerinden optimum eşik değerinin belirlenmesi, hem yanlış pozitifleri azaltmak hem de bozulmaları kaçırmamak açısından önem arz etmektedir. Uygun eşik değeri seçimiyle hem hatalı pozitiflerin azaltılması hem de kritik yüzey kusurlarının gözden kaçırılmaması sağlanabilir. Bu tür analizler, özellikle saha uygulamaları için karar destek mekanizması görevi görür.
- Gerçek Uygulama Performansı (Test Seti): örnek test verisi çıktıları, modelin daha önce görmediği yüzeylerde dahi başarılı tespitler yapabildiğini ortaya koymuştur. Elde edilen sonuçlar, modelin saha koşullarında yer alan yüzey bozulmalarını konum ve sınıf bazında başarılı biçimde tespit edebildiğini göstermektedir. Görsel doğrulamalar, modelin yalnızca sayısal metriklerde değil, gerçek dünya uygulamalarında da etkin bir performans sunduğunu ortaya koymaktadır.
- Mühendislik Uygulamalarına Katkısı: Bu model, geleneksel yüzey bozulma tespiti yöntemlerine kıyasla daha hızlı, sistematik ve otomatik bir çözüm sunmaktadır.

Geliştirilen yapay zekâ tabanlı yaklaşım, özellikle pist, taksiyolu ve apron gibi kritik altyapı elemanlarında yüzey sağlığının sürekli izlenmesi ve bozulmaların erken evrede tespit edilmesi açısından yüksek potansiyel taşımaktadır. Bu yönüyle model, bakım planlamaları ve kaynak optimizasyonu süreçlerine veri destekli kararlar sağlayabilecek niteliktedir.

Modelin deformasyonlarının türlerini ayırt etmede ve konumlarını belirlemede sağladığı başarı ve bakım süreçleri için sağlayacağı avantajlar göz önünde bulundurularak, çalışmamız kapsamında geliştirilen model, geleneksel hasar tespit yöntemlerine göre daha hızlı, otomatik ve ölçeklenebilir bir çözüm sunduğu izah edilmeye çalışılmıştır. Bu sayede:

- Görüntü işleme tabanlı bu yöntem sayesinde manuel kontrollerin yerine, sürekli ve sistematik bir gözlem mekanizması kurulabilir.
- Ayrıca elde edilen metrikler, bakım ve onarım planlarının veri destekli ve önceliklendirilmiş şekilde yapılmasına olanak tanır.

Model hem eğitim sürecinde hem de test aşamasında istikrarlı, doğru ve uygulanabilir sonuçlar vermiştir. Sınırlı veriyle yüksek doğruluk elde edilmesi, sistemin güçlü bir potansiyele sahip olduğunu gösterir. Bu yapıdaki bir model, gelecekte daha geniş veri setleri ve farklı yüzey tipleriyle eğitildiğinde, saha uygulamalarında etkin bir karar destek aracı olarak kullanılabilir.

Ayrıca bu çalışma, yalnızca elde edilen sonuçlarla sınırlı kalmayıp, ileride yapılacak çalışmalara da yön verecek nitelikte öneriler geliştirmektedir. Mevcut çalışmada iPhone 11 kamerası ile elde edilen görüntüler kullanılmış olsa da ilerleyen süreçlerde havaalanlarında kullanılan araçlara (örneğin apron araçları, bakım robotları, dronelar, helikopterler veya pist kontrol araçları) entegre edilebilecek yüksek çözünürlüklü kameralar sayesinde daha kaliteli ve kapsamlı veri toplanabilecektir. Bu kameralar aracılığıyla elde edilen görüntüler, gerçek zamanlı olarak analiz sistemlerine aktarılabilir; anlık çatlak tespiti ve konum belirleme mümkün hale gelebilir.

Buna ek olarak, daha kapsamlı veri setleri ve ileri düzey algoritmalar kullanılarak hasar tespitinin yanı sıra hasarın tipi, boyutu, ilerleme riski gibi detaylar da sınıflandırılabilir. Hatta yapay zeka destekli sistemlerin, analiz sonucunda önerilen bakım yöntemi ve aciliyet düzeyi gibi karar destek bilgilerini de sağlayabileceği ileri sistemler geliştirilebilir.

## Öneriler

- Modelin anlık görüntü akışı ile çalışacak şekilde geliştirilmesi, uçuş öncesi rutin kontrollerin daha etkin ve hızlı gerçekleştirilmesini sağlayacaktır.

- Farklı havaalanlarından, çeşitli ışık, yüzey türü ve iklim koşullarını içeren geniş veri setleri toplanarak modelin genelleştirilebilirliği ve doğruluğu artırılabilir.
- Hasar tespiti ile sınırlı kalmayıp, hasarın sınıflandırılması, önceliklendirilmesi ve uygun bakım yöntemlerinin önerilmesi gibi fonksiyonlar modele entegre edilebilir.
- Modelin taşınabilir cihazlar veya drone tabanlı denetim sistemlerine entegre edilmesi, saha denetimlerinin daha esnek ve hızlı yapılmasına imkan tanıyacaktır.
- Modelden elde edilen veriler havaalanı bakım yönetim sistemleri ile otomatik olarak entegre edilerek, iş emirleri ve bakım planlaması süreçleri hızlandırılabilir ve operasyonel verimlilik artırılabilir.

Sonuç olarak bu çalışma, havaalanı üstyapı yönetiminde özellikle kaplamalı saha yüzeylerinde güvenliği artırmak, manuel denetimin getirdiği zorlukları azaltmak, altyapı izleme ve bakım alanında ileriye doğru önemli bir sıçrama sunmak ve teknolojik çözümler aracılığıyla daha verimli bir bakım-onarım stratejisi geliştirmek amacıyla atılmış önemli bir adımdır. Hem sivil hem askeri havacılıkta, operasyonel sürekliliği ve güvenliği sağlamak için benzer yapay zeka tabanlı uygulamaların yaygınlaştırılması büyük fayda sağlayacaktır. Otomatik denetim sistemlerini, gelişmiş sorun tespit algoritmalarını ve yenilikçi İHA uygulamalarını entegre ederek, havalimanları yönetim süreçlerini önemli ölçüde geliştirebilir ve uzun vadede daha fazla güvenlik ve maliyet verimliliği sağlayabilir. Gelecekteki araştırmalar, bu teknolojileri geliştirmeye devam etmeli ve hava yolculuğu ve havacılık altyapısı bakımının artan talepleriyle birlikte gelişmelerini sağlamalıdır.

## KAYNAKLAR

- Akın, E., Şahin, M.E., 2023 Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme, RTEÜ, Rize
- Alzubaidi, LL., Zhang, J., Humaidi2 A.J., AL-Dujaili, A., Duan, Y., AL-Shamma, O., Santamaria, J., Fadhel, M.A., AL-Amidie, M., Farhan, L., 2021 Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions
- Aparna, Bhatia, Y., Rai, R., Gupta, V., Aggarwal, N., & Akula, A. (2019). Convolutional Neural Networks Based Potholes Detection Using Thermal Imaging. *Journal of King Saud University-Computer and Information Sciences*.  
<https://doi.org/10.1016/j.jksuci.2019.02.004>
- Ashford, N., Wright, P.H., 1992, Airport Engineering, John Wiley&Sons
- ATSB. (2016, May 27). *Foreign object damage involving a Eurocopter AS365 N3 Dauphin, VH-WPX*. [www.atsb.gov.au](http://www.atsb.gov.au).  
<https://www.atsb.gov.au/sites/default/files/media/5770449/ao-2015-127-final.pdf>
- Avcı, B. O. (2021, October 28). *Pistte Oluşan Lastik İzleri Nasıl Temizlenir*. Herkes İçin Havacılık Derneği. <https://herkesicinhavacilik.com/2021/10/28/pistte-olusan-lastik-izleri-nasil-temizlenir/>
- Babashamsi, P., Khahro, S., Omar, H., Al-Sabaei, A., Memon, A., Milad, A., & Yusoff, N. (2022). Perspective of life-cycle cost analysis and risk assessment for airport pavement in delaying preventive maintenance. *Sustainability*, 14(5), 2905.  
<https://doi.org/10.3390/su14052905>
- Bao-li, W., Guo, C., & Miao-yi, D. (2022). An innovation of the Markov probability model for predicting the remaining service life of civil airport rigid pavements. *Materials*, 15(17), 6082. <https://doi.org/10.3390/ma15176082>
- Baygın, M., Yaman, O., & Tuncer, T. (2021). Akıllı Şehirler için Özellik Çıkarımı ve Makine Öğrenmesi Tabanlı Asfalt Durum İzleme Yaklaşımı. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.844592>
- CAO, W., Liu, Q., & He, Z. (2020). Review of Pavement Defect Detection Methods. *IEEE Access*, 8, 14531–14544. <https://doi.org/10.1109/access.2020.2966881>
- CAO, Y., & Sun, Y. (2024). *The research on the application of deep learning in education*. IETI Transactions on Data Analysis and Forecasting, 2(3), 4–11.  
<https://doi.org/10.3991/itdaf.v2i3.51413>
- Cartwright, M. (2016, Mayıs 12). Daidalos [Daedalus]. (B. Étienne-Cartwright, Çevirmen). *World History Encyclopedia*. Alınmıştır <https://www.worldhistory.org/trans/tr/1-14758/daidalos/>
- Chatterjee, S., Saeedfar, P., Tofangchi, S., & Kolbe, L. M. (2018). Intelligent Road Maintenance: a Machine Learning Approach For Surface Defect Detection. *European Conference on Information Systems*, 194.  
[https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1193&context=ecis2018\\_rp](https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1193&context=ecis2018_rp)

- Cordovil, R., Santos, A., Dagher, R., & Moraes, H. (2022). M&R strategies based on PCI assessments in the framework of an SMS in a military airport network. *Journal of Engineering Research*, 2(28), 2–14. <https://doi.org/10.22533/at.ed.31722822021210>
- Crouch, T. D. (1998, July 20). *Wright flyer of 1903 | First Airplane Flight, Aviation History | Britannica. Encyclopedia Britannica*. <https://www.britannica.com/topic/Wright-flyer-of-1903>
- Czimmermann, T., Ciuti, G., Milazzo, M., Chiurazzi, M., Roccella, S., Oddo, C., ... Dario, P. (2020). *Visual-based defect detection and classification approaches for industrial applications—A survey*. *Sensors*, 20(5), 1459. <https://doi.org/10.3390/s20051459>
- Çullu, M., Subaşı, S., Bolat, H., (2010). Beton Kanseri-Alkali Silika Reaksiyonu, HÜ, DÜ, ANKARA
- Deveci, E., Ergen, B. (2021). Yol Yüzey Anormalisinin Tespiti ve Analizi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*. <https://doi.org/10.17798/bitlisfen.942386>
- DHMI. (2021). *DHMI Hakkında Ders Notu 2021*. [www.dhmi.gov.tr](http://www.dhmi.gov.tr). [https://ssd.dhmi.gov.tr/PublishingImages/Lists/HavacilikEgitim\\_Duyurular/NewForm/DHMI%20HAKKINDA%20DERS%20NOTU%20-%20UZMAN.pdf](https://ssd.dhmi.gov.tr/PublishingImages/Lists/HavacilikEgitim_Duyurular/NewForm/DHMI%20HAKKINDA%20DERS%20NOTU%20-%20UZMAN.pdf)
- DHMI. (2025). *İstatistikler*. Devlet Hava Meydanları İşletmesi Genel Müdürlüğü. <https://dhmi.gov.tr/Sayfalar/Istatistikler.aspx>
- DHMI. (Mayıs,2025). *Devlet Hava Meydanları İşletmesi Genel Müdürlüğü Faaliyet Raporu 2024*. Devlet Hava Meydanları İşletmesi Genel Müdürlüğü. [https://www.dhmi.gov.tr/Lists/FaaliyetRaporlari/Attachments/25/54974\\_faaliyetraporu2024.pdf](https://www.dhmi.gov.tr/Lists/FaaliyetRaporlari/Attachments/25/54974_faaliyetraporu2024.pdf)
- DHMI. (t.y.-a). *Ankara Esenboğa havalimanı*. Devlet Hava Meydanları İşletmesi Genel Müdürlüğü. <https://dhmi.gov.tr/Sayfalar/Havalimani/Esenboga/AnaSayfa.aspx>
- DHMI. (t.y.-b). *Ordu Giresun Havalimanı*. Devlet Hava Meydanları İşletmesi Genel Müdürlüğü. <https://www.dhmi.gov.tr/sayfalar/havalimani/ordugiresun/anasayfa.aspx>
- DLH., 2007 Havameydanları Planlama ve Tasarım Teknik Esasları, Ankara
- Doğan, F., Türkoğlu, İ., 2018 Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, Derleme Makalesi
- Doğan, U.F., 2025 Cracknet-Uçak Pistlerindeki Çatlakların Tespiti İçin Bir Mobil Uygulama, KBÜ, KARABÜK
- Dokuz, Y., & Tüfekçi, Z. (2020). A Review on Deep Learning Architectures for Speech Recognition. *European Journal of Science and Technology*, (Özel Sayı), 169-176.
- Erdem, M.,2010 Sivil Havacılık Sektöründe Gelir Yönetimi: Türk Hava Yolları Anonim Ortaklığı Uygulaması. Yüksek Lisans Tezi, İÜ. Sosyal Bilimler Enstitüsü, İSTANBUL
- Erdoğan, A. (2019, December 3). *Asfalt Betonu Kaplamalarda Meydana Gelen Bozulmalar, Nedenleri ve İyileştirilmeleri*. BiŞantiye. <https://www.bisantiye.com/asfalt-betonu-kaplamalarda-meydana-gelen-bozulmalar-nedenleri-ve-iyilestirilmeleri/>
- Evren, E. (t.y.). *GPR Ground Penetrating Radar Nedir*. [web.itu.edu.tr](http://web.itu.edu.tr). <https://web.itu.edu.tr/evrene/GPR.html>
- FAA,1995, AC 150/5320-6D Airport Pavement Design and Evaluation. FAA.
- FPrimeC. (n.d.). *Ground Penetrating Radar (GPR)- FPrimeC Solutions Inc*. FPrimeC Solutions Inc. <https://fprimec.com/services/ground-penetrating-radar-gpr/>

- Gagliardi, V., Giammorcaro, B., Francesco, B., & Sansonetti, G. (2023). Deep neural networks for asphalt pavement distress detection and condition assessment. <https://doi.org/10.1117/12.2688512>
- Ghosh, A. (2025, March 10). *YOLO11: Redefining Real-Time Object Detection - Tutorial*. LearnOpenCV – Learn OpenCV, PyTorch, Keras, Tensorflow With Code, & Tutorials. <https://learnopencv.com/yolo11/>
- Guo, W., Wang, N., & Fang, H. (2021). Design of airport road surface inspection system based on machine vision and deep learning. *Journal of Physics: Conference Series*, 1885(5), 052046. <https://doi.org/10.1088/1742-6596/1885/5/052046>
- Güneşen.N.M., 2003. Cumhuriyetten Günümüze Türk Havacılığı. Yüksek Lisans Tezi, HÜ Atatürk İlkeleri ve İnkılap Tarihi Enstitüsü, ANKARA
- Hanlı, E., 2009 Esnek Yol Üstyapısında Oluşan Bozulmalar ve Değerlendirmesi. Yüksek Lisans Tezi, İTÜ. Fen Bilimleri Enstitüsü, İSTANBUL
- Hastings, R., Quinn, M., Bernier, A., & Rutland, C. (2022). *A review of airfield pavement drainage guidance*. US Army Corps of Engineers Digital Library. <https://doi.org/10.21079/11681/45720>
- Ibragimov, E., Kim, Y., Lee, J., Cho, J., & Lee, J. (2024). Automated pavement condition index assessment with deep learning and image analysis: An end-to-end approach. *Sensors*, 24(7), 2333. <https://doi.org/10.3390/s24072333>
- ICAO, Airport Services Manual (Doc 9137), Part 2 Pavement Surface Conditions, Fourth Edition, 2002
- Insapedia. (2018, August 16). *Asfalt Yollarda Meydana Gelen Kusur ve Hasar Çeşitleri*. <https://insapedia.com/asfalt-yollarda-meydana-gelen-kusur-ve-hasar-cesitleri/>
- Irvayana, I., Astor, Y., Sihombing, A., & Sundara, A. (2022). Analysis of runways surface conditions using pavement condition index method (Case study: I Gusti Ngurah Rai International Airports). *RSF Conference Series: Engineering and Technology*, 2(2), 1–11. <https://doi.org/10.31098/cset.v2i2.554>
- IT-ZEB Server. (t.y.). *Alt Proje 3 (TP3)*. IT-ZEB Server. [https://itzeb.heller-ig.de/zeb\\_tp3.html](https://itzeb.heller-ig.de/zeb_tp3.html)
- İGA, 2019 İstanbul Airport Emniyet Bülteni 2019-14 Rev-01
- İnik, Ö., ÜLKER, E., 2017 Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, GBAD, TOKAT
- Kanaeva, I. A., & Ivanova, J. A. (2021). Road pavement crack detection using deep learning with synthetic data. *IOP Conference Series: Materials Science and Engineering*, 1019, 012036. <https://doi.org/10.1088/1757-899x/1019/1/012036>
- Kanburoğlu, E., (2022, July 8). Karayolu Üstyapılarında Görülen 6 Önemli Bozulma Tipi ve Onarım Yöntemleri. Sanal Şantiye. <https://www.sanalsantiye.com/karayolu-ustyapilarinda-gorulen-6-onemli-bozulma/>
- Kang, D., & Cha, Y. (2018). *Autonomous UAVs for structural health monitoring using deep learning and an ultrasonic beacon system with geo-tagging*. *Computer-Aided Civil and Infrastructure Engineering*, 33(10), 885–902. <https://doi.org/10.1111/mice.12375>
- Kaşak, S., Komut, M., Altıok, Ş. (2019, Kasım). 1.Beton Yollar Kongresi ve Sergisi. *Ülkemiz Karayolları İçin Beton Yol Projelendirme Rehberi Çalışmaları ve Beton Sınıfına Bağlı Beton Plak Kalınlıkları*. (13-14 Kasım 2019, Ankara)
- Kaya, A., Karaca, A.N., Doğan, H., Sacar, Ö., MEB, Havacılık Yönetimi Ders Kitabı 10, 2020. Havacılık Yönetimi Ders Kitabı 10, MEB, 162p, TÜRKİYE

- Kılıç, G., 2022 Yer Radarı (GPR) Uygulaması ile Kısmi Yıkılmış Bir Köprünün Sağlık Durumunun Belirlenmesi, İzmir Ekonomi Üniversitesi, İnşaat Mühendisliği Bölümü
- Kılıç, H. (1993). *CEVHERİ, İsmâil b. Hammâd - TDV İslâm Ansiklopedisi*. TDV İslâm Ansiklopedisi. <https://islamansiklopedisi.org.tr/cevheri-ismail-b-hammad>
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2015). A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29(2), 196–210. <https://doi.org/10.1016/j.aei.2015.01.008>
- Kök, Ç., 2008 Karayolu ve Havaalanı Üstyapı Tasarım Yöntemleri, Karşılaştırması ve Türkiye Uygulamaları Yüksek Lisans Tezi, İTÜ. Fen Bilimleri Enstitüsü, İSTANBUL
- Köker, İ. (2018, October 27). *İstanbul Havalimanı ile ilgili bugüne kadar neler iddia edildi, inşaatı gerçekleştiren İGA nasıl yanıt verdi? - BBC News Türkçe*. BBC News Türkçe. <https://www.bbc.com/turkce/haberler-turkiye-45990455>
- Kuloğlu, N., Özdemir, M.A., & Kök, B.V., (2007). Evaluation of Airport Flexible Pavement Design Methods. 7th Transport Congress, 19-21 September, Istanbul.
- Kumar, D., Taylor, G., & Wong, A. (2017). *Opening the black box of financial ai with clear-trade: a class-enhanced attentive response approach for explaining and visualizing deep learning-driven stock market prediction*. Journal of Computational Vision and Imaging Systems, 3(1). <https://doi.org/10.15353/vsnl.v3i1.166>
- Kutluhan, S., AĞAR, E., 2009 Bitümlü Sıcak Karışımlarda Tekerlek İzi Oluşumunu Etkileyen Faktörler ve Azaltmaya Yönelik Öneriler, İTÜ Fen Bilimleri Enstitüsü
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- LI, M., Huang, Z., Shan, Q., Chen, S., Zhang, N., Matsumoto, S., ... & Wang, W. (2022). Performance and comparison of artificial intelligence and human experts in the detection and classification of colonic polyps. *BMC Gastroenterology*, 22(1). <https://doi.org/10.1186/s12876-022-02605-2>
- Macchiarulo, V., Milillo, P., Blenkinsopp, C. ve Giardina, G., (2022). Monitoring deformations of infrastructure networks: A fully automated GIS integration and analysis of InSAR timeseries. *Structural Health Monitoring*, 147592172110459. <https://doi.org/10.1177/14759217211045912>
- Meng, Q., Zhong, K., & Sun, M. (2023). Dynamic response analysis of airport pavement under impact loading. *Applied Sciences*, 13(9), 5723. <https://doi.org/10.3390/app13095723>
- Meng, Q., Zhong, K., Li, Y., & Sun, M. (2024). Comparative study on mechanical response in rigid pavement structures of static and dynamic finite element models. *Aerospace*, 11(7), 596. <https://doi.org/10.3390/aerospace11070596>
- Mesci, Y. (2021, December 9). YOLO Algoritmasını Anlamak - Deep Learning Türkiye-Medium. *Medium*. <https://medium.com/deep-learning-turkiye/yolo-algoritmas%C4%B1n%C4%B1-anlamak-290f2152808f>
- Mohan, A., & Poobal, S. (2017). Crack detection using image processing: A critical review and analysis. *Alexandria Engineering Journal*, 57(2), 787–798. <https://doi.org/10.1016/j.aej.2017.01.020>
- Mukherjee, S. (2024b, October 18). *What's new in YOLOV11 Transforming Object Detection Once Again Part 1*. DigitalOcean. <https://www.digitalocean.com/community/tutorials/what-is-new-with-yolo?utm>

- NATO Gv.Yat.D.Bk.lıĖı Kaliteli Beton Kaplama artnamesi,2025
- Okur, F., 2008 Havaalanı styapı Tasarım Yntemleri. Yksek Lisans Tezi, İT. Fen Bilimleri Enstits, İSTANBUL
- zdemir, M.A., 2010 Havaalanı Esnek styapı Tasarım Yntemlerinin Karılatırılması. Yksek Lisans Tezi, F. Fen Bilimleri Enstits, ELAZIĖ
- zgr, S.B., 2021 Algoritmalar, Yapay Zeka, Makine Ėrenmesi, Derin Ėrenme ve Uygulamaları: Beeri Fayda retiminin Yazılımlar Tarafından Karılanması, Aratırma Makalesi,
- ztemel, E. (2022). Yapay Zekâ ve Makine Ėrenmesi. Tbitak- Ansiklopedi. [https://ansiklopedi.tubitak.gov.tr/ansiklopedi/yapay\\_zeka\\_ve\\_makine\\_ogrenmesi](https://ansiklopedi.tubitak.gov.tr/ansiklopedi/yapay_zeka_ve_makine_ogrenmesi)
- ztrk, P. F. (2021, AĖustos 9). *Alman planr mucidi Otto Lilienthal*. Havacılık, Savunma, Uzay ve Teknoloji Haberleri. <https://haber.aero/yazarlar/fahrettin-ozturk/alman-planor-mucidi-otto-lilienthal/>
- Perez, H., Tah, J., & Mosavi, A. (2019). Deep learning for detecting building defects using convolutional neural networks. *Sensors*, 19(16), 3556. <https://doi.org/10.3390/s19163556>
- Portland Cement Association, "Thickness Design for Concrete Pavement", 1966, Portland Cement Association
- Prokopets, E. (2025, 3 Haziran). *Tahribatsız Muayene Ekipmanları Rehberi*. Voliro. <https://voliro.com/blog/non-destructive-testing-equipment/>
- Ravı, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Prez, J., Lo, B., & Yang, G. (2017). Deep learning for health informatics. *Ieee Journal of Biomedical and Health Informatics*, 21(1), 4-21. <https://doi.org/10.1109/jbhi.2016.2636665>
- Seker. S.E., 2015 DoĖal Dil İleme (Natural Language Processing), Istanbul Medeniyet University.
- Serin, S., SALTAN, M., & TERZİ, S. (2022). D330 Karayolu Burdur Kesiminde GPR ile Karayolu styapı Tabaka KalınlıĖı ve Tabakalardaki Anormalliklerin Belirlenmesi. *Sleyman Demirel niversitesi Fen Bilimleri Enstits Dergisi*, 305–313. <https://doi.org/10.19113/sdufenbed.1000547>
- SHGM (2025) *lkemizdeki Havaalanlarına Ait Bilgiler | Sivil Havacılık Genel MdrlĖ*. (n.d.). Anasayfa | Sivil Havacılık Genel MdrlĖ. <https://web.shgm.gov.tr/tr/havaalanlari/381-havaalanlari>
- SHGM, Havaalanı Kaplama Yzey Koulları HAD/T-33, Aralık 2017
- SHGM. (Mayıs,2025). *Sivil Havacılık Genel MdrlĖ Faaliyet Raporu 2024*. Sivil Havacılık Genel MdrlĖ. <https://web.shgm.gov.tr/tr/kurumsal/4006-faaliyet-raporlarimiz>
- SHI, P., Liang, K., Han, D., & Zhang, Y. (2017). A novel intelligent fault diagnosis method of rotating machinery based on deep learning and pso-svm. *Journal of Vibroengineering*, 19(8), 5932-5946. <https://doi.org/10.21595/jve.2017.18380>
- SıĖırcı, M. (2022, ubat 26). *Uak: Kim, Ne Zaman İcat Etti?* | TBİTAK Bilim Gen. Bilim Genc. <https://bilimgenc.tubitak.gov.tr/makale/ucak-kim-ne-zaman-icad-etti>
- Skybrary. (n.d.). *Foreign Object Debris and Damage Prevention | SKYbrary Aviation Safety*. SKYbrary Aviation Safety. <https://skybrary.aero/articles/foreign-object-debris-and-damage-prevention>

- Solak, S., Altınışik, U., 2017 Görüntü İşleme Teknikleri ve Kümeleme Yöntemleri Kullanılarak Fındık Meyvesinin Tespit ve Sınıflandırılması, KÜ, KOCAELİ
- Soytürk, M., Doğan, F., Şaşmaz, E., Böyük, Ş., (2014). Yol Yüzey Bozukluklarının Tespit ve Analizi, MÜ, İSTANBUL
- SU, X. (2024). Vision recognition and positioning optimization of industrial robots based on deep learning. *Journal of Artificial Intelligence Practice*, 7(2). <https://doi.org/10.23977/jaip.2024.070207>
- Şebin, B. (2022, September 4). Evrimsel sinir ağı (Convolutional Neural network). *Medium*. <https://medium.com/@sebinbusra/evri%C5%9Fimsel-sinir-a%C4%B1-convolutional-neural-network-f49f7b65c72>
- Şeker, A., Diri, B., Balık, HH (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *DergiPark* (İstanbul Üniversitesi). <https://dergipark.org.tr/tr/pub/gmbd/issue/31064/372661>
- Şimşek, U., & Özdemir Tosun, H. (2025, January 4). *Antalya 2024'te yaklaşık 17,3 milyon ziyaretçiyle tarihi rekor kırdı.* Anadolu Ajansı. <https://www.aa.com.tr/tr/ekonomi/antalya-2024te-yaklasik-17-3-milyon-ziyaretciyle-tarihi-rekor-kirdi/3440837>.
- Tekin, Z., 2023 [https://tasam.org/Files/Icerik/File/Derin\\_%C3%96%C4%B1n%C4%B1n\\_G%C3%BCc%C3%BC\\_pdf\\_fb76ffe2-bf1f-40d3-85c9-28fda47462f9.pdf](https://tasam.org/Files/Icerik/File/Derin_%C3%96%C4%B1n%C4%B1n_G%C3%BCc%C3%BC_pdf_fb76ffe2-bf1f-40d3-85c9-28fda47462f9.pdf)
- THK. (t.y.-a). *Türk Hava Kurumu- Türk Tayyare Cemiyeti (T.Ta.C.). Türk Hava Kurumu- Ana Sayfa.* [https://www.thk.org.tr/turk\\_tayyare\\_cemiyeti](https://www.thk.org.tr/turk_tayyare_cemiyeti)
- THK. (t.y.-b). *Türk Hava Kurumu - Kurumu-ÜRKÜŞ. Türk Hava Kurumu- Ana Sayfa.* [https://www.thk.org.tr/vecihi\\_hurkus](https://www.thk.org.tr/vecihi_hurkus) *Türk Hava Yolları- (THY), Türk Hava Yolları (n.d.). - Ana Sayfa.* <https://www.turkishairlines.com/tr-tr/basin-odasi/hakkimizda/hikayemiz/>
- THY. (t.y.-a). *Hikayemiz | Hakkımızda | Türk Hava Yolları ®.* <https://www.turkishairlines.com/tr-tr>. <https://www.turkishairlines.com/tr-tr/basin-odasi/hakkimizda/hikayemiz/>
- THY. (t.y.-b). *Türk Hava Yolları- Yatırımcı İlişkileri.* *Türk Hava Yolları- Yatırımcı İlişkileri* <https://investor.turkishairlines.com/tr>. <https://investor.turkishairlines.com/tr/mali-ve-operasyonel-veriler/uculan-hatlar>
- THY. (t.y.-c). *Türk Hava Yolları- Yatırımcı İlişkileri.* *Türk Hava Yolları- Yatırımcı İlişkileri.* <https://investor.turkishairlines.com/tr/mali-ve-operasyonel-veriler/filo>
- Tunç, A., 2003, Havaalanı Mühendisliği ve Uygulamaları, Asil Yayın Dağıtım, Ankara
- Türk Çimento, 2024 Silindire Sıkıştırılmış Beton (SSB) Yollar Bakım ve Onarım Rehberi
- Türkmen, E., 2021 Makine Öğrenmesi Yöntemleri ile Banka Pazarlama Tahmini, Yüksek Lisans Tezi, İKÜ, İSTANBUL
- Ultralytics. (2025, July 19). *Bilgisayarlı Görme (CV).* Ultralytics | Revolutionizing the World of Vision AI. <https://www.ultralytics.com/tr/glossary/computer-vision-cv>
- US Army Corps of Engineers, 2001, Unified Facilities Criteria (UFC) 3-260-02, Washington DC.
- Vitoria, P., Raad, L., Ballester, C., 2020 ChromaGAN: Adversarial Picture Colorization with Semantic Class Distribution, University Pompeu Fabra, Barcelona

- Vina, A. (2025, April 2). *YOLO Model Comparison: YOLOv11 vs Previous*. <https://www.ultralytics.com/tr/blog/comparing-ultralytics-yolo11-vs-previous-yolo-models>
- Warrrip. (2019, October). Western Australian Road Research and Innovation Program. [https://warrrip.com.au/wp-content/uploads/2023/01/WARRIP-Project-Report-2019-006-Optimise-laser-data\\_Report\\_2019-10-18\\_Final\\_WebEdit.pdf](https://warrrip.com.au/wp-content/uploads/2023/01/WARRIP-Project-Report-2019-006-Optimise-laser-data_Report_2019-10-18_Final_WebEdit.pdf)
- Wesołowski, M., Blacha, K., & Barszcz, P. (2017). Multi-criteria analysis in assessment of the degree of degradation pavement elements functional airports made of cement concrete. In *10th International Conference Environmental Engineering* (No. 125). <https://doi.org/10.3846/enviro.2017.125>
- Wildml. (2016). "Understanding Convolutional Neural Networks For NLP." from <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>
- XU, L., Lai, Y., Ma, D., Wang, J., Li, M., Li, L., & Zhang, Y. (2022). Effects of fiber and surface treatment on airport pavement concrete against freeze–thawing and salt freezing. *Materials*, 15(21), 7528. <https://doi.org/10.3390/ma15217528>
- Yang, Z., Nashik, S., Huang, C., Aibin, M., & Coria, L. (2024). Next-gen remote airport maintenance: UAV-guided inspection and maintenance using computer vision. *Drones*, 8(6), 225. <https://doi.org/10.3390/drones8060225>

## ÖZGEÇMİŞ

|                                                                                                                                                                              |                                                                                             |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------|
| <b>Kişisel Bilgiler</b>                                                                                                                                                      |                                                                                             |
| <b>Adı Soyadı:</b>                                                                                                                                                           | Yasin YILDIRIM                                                                              |
| <b>Doğum tarihi:</b>                                                                                                                                                         |                                                                                             |
| <b>Doğum Yeri:</b>                                                                                                                                                           |                                                                                             |
| <b>Uyruğu:</b>                                                                                                                                                               |                                                                                             |
| <b>Adres:</b>                                                                                                                                                                |                                                                                             |
| <b>Tel:</b>                                                                                                                                                                  |                                                                                             |
| <b>E-mail:</b>                                                                                                                                                               |                                                                                             |
| <b>Eğitim</b>                                                                                                                                                                |                                                                                             |
| <b>Lise:</b>                                                                                                                                                                 | Karabük Demir Çelik Lisesi                                                                  |
| <b>Lisans:</b>                                                                                                                                                               | Süleyman Demirel Üniversitesi, Mühendislik Mimarlık<br>Fakültesi İnşaat Mühendisliği Bölümü |
| <b>Yüksek lisans:</b>                                                                                                                                                        | Atatürk Üniversitesi                                                                        |
| <b>Yabancı Dil Bilgisi</b>                                                                                                                                                   |                                                                                             |
| <b>İngilizce:</b>                                                                                                                                                            | Orta                                                                                        |
| <b>Üye Olunan Mesleki Kuruluşlar</b>                                                                                                                                         |                                                                                             |
| İnşaat Mühendisleri Odası                                                                                                                                                    |                                                                                             |
| <b>Tezden Üretilmiş Yayınlar</b>                                                                                                                                             |                                                                                             |
| 1. Havaalanı Ulaşımında Kaplamalı Saha Konfor Şartları ve Yüzey Pürüzlülüğü<br>(The First International Congress of Nature, Science & Technology (NSET-2025-<br>Palandöken)) |                                                                                             |
| 2. Havaalanı Esnek Kaplamalı Pist Yüzeyinde Oluşan Yüzey Kusurlarının Çok<br>Kriterli Karar Verme Yöntemi İle Analizi                                                        |                                                                                             |